

010101010101

0101010101

01010101

# 数据仓库与数据挖掘

## 原理及应用

郑岩 编著

Data Warehouse

Data Mining

01010101010101010101010101010101

清华大学出版社

01010101010101010101010101010101

# 数据仓库与数据挖掘 原理及应用

郑 岩 编著

清华大学出版社  
北 京



## 内 容 简 介

本书从专业角度全面介绍了数据仓库和数据挖掘的理论、方法、技术及其应用,系统地阐述了数据仓库和数据挖掘的产生、发展和应用及其主要概念、原理和算法,并结合当前数据仓库和数据挖掘中一些新的应用实例进一步加以说明,力求学以致用。

全书分为三篇。第一篇介绍数据仓库的起源和演变过程,阐述数据仓库的定义、体系结构、组成、元数据、数据粒度和数据模型以及 ETL 过程,论述数据仓库设计和实现的方法。结合具体应用详细阐述了如何构建数据仓库及其主要应用,包括 OLAP 和 OLAM 等。第二篇介绍数据挖掘的起源和发展趋势,以及数据挖掘与 Web 挖掘的技术和方法,包括聚类、分类、预测和关联分析等,详细分析了数据挖掘在电信领域的具体应用,如客户细分、重入网识别和 WAP 日志挖掘等。第三篇讨论数据、信息和知识的关系,论述知识表示的主要方法和知识管理的核心技术,介绍当前研究热点——语义网和本体的核心技术和方法,分析了语义网和本体的主要应用。

本书可作为计算机专业研究生或高年级本科生教材,也可以作为计算机研究和开发人员以及相关专业人士的参考资料。

本书封面贴有清华大学出版社防伪标签,无标签者不得销售。

版权所有,侵权必究。侵权举报电话:010-62782989 13701121933

## 图书在版编目(CIP)数据

数据仓库与数据挖掘原理及应用/郑岩编著. —北京:清华大学出版社,2011.1

ISBN 978-7-302-22819-6

I. ①数… II. ①郑… III. ①数据库系统 ②数据采集 IV. ①TP311.13 ②TP274

中国版本图书馆 CIP 数据核字(2010)第 097105 号

责任编辑:梁 颖 顾 冰

责任校对:时翠兰

责任印制:

出版发行:清华大学出版社

地 址:北京清华大学学研大厦 A 座

<http://www.tup.com.cn>

邮 编:100084

社 总 机:010-62770175

邮 购:010-62786544

投稿与读者服务:010-62795954, [jsjic@tup.tsinghua.edu.cn](mailto:jsjic@tup.tsinghua.edu.cn)

质 量 反 馈:010-62772015, [zhiliang@tup.tsinghua.edu.cn](mailto:zhiliang@tup.tsinghua.edu.cn)

印 刷 者:

装 订 者:

经 销:全国新华书店

开 本:185×260

印 张:19.5

字 数:464 千字

版 次:2011 年 1 月第 1 版

印 次:2011 年 1 月第 1 次印刷

印 数:1~ 000

定 价: .00 元

产品编号:



01  
0101010101010101010101010101010101

前

言

数据仓库是将大量传统数据库数据进行抽取、清洗和转换,并按主题进行重新组织,可比喻为随时间推移不断丰富的“宝藏”;而数据挖掘是从海量数据中发现人们感兴趣的知识,这些知识是隐含的、事先未知的潜在有用信息,挖掘的知识表示形式为概念、规则、规律和模式等,可比喻为“淘宝”。随着 Internet 的迅速普及和广泛应用,每天都产生大量各种各样的信息,但它们背后到底隐藏着什么,这驱使人类不断探索。

工欲善其事必先利其器。在当今信息爆炸的时代,数据挖掘堪比“利器”,让我们面对海量数据时不再感到茫然和不知所措。随着数据仓库的发展和应用,数据挖掘将展现无限的生机和活力,可以辅助、部分代替甚至拓展人的智能和决策,造福人类。

数据经整合汇总为信息,信息经挖掘抽象为知识,知识是智能的基石。因此,信息化到知识化再到智能化将是人类社会发展的必然趋势。数据仓库和数据挖掘正逐步渗透和深入到社会的各个领域,并不断催生新的应用。

本书主要介绍数据仓库和数据挖掘的理论、方法、技术及其应用。此外,用较多篇幅阐述数据仓库和数据挖掘新的应用实例。

全书分为三篇。第一篇介绍数据仓库的起源和演变过程,阐述数据仓库的定义、体系结构、组成、元数据、数据粒度和数据模型以及 ETL 过程,论述数据仓库设计和实现的方法,并结合具体应用详细阐述了如何构建数据仓库及其主要应用,包括 OLAP 和 OLAM 等。第二篇介绍数据挖掘的起源和发展趋势,以及数据挖掘与 Web 挖掘的技术和方法,包括聚类分析、分类、预测和关联分析等,详细分析了数据挖掘在电信领域的具体应用,如客户细分、重入网识别和 WAP 日志挖掘等。第三篇讨论数据、信息和知识的关系,论述知识表示的主要方法和知识管理的核心技术,介绍当前研究热点——语义网和本体的核心技术和方法,分析了语义网和本体的主要应用。

本书编写过程中,参考了许多专家和学者的著作和论文,在此谨向他们表示衷心感谢。

作者潜心撰写历时多年完成,旨在奉献精品以飨广大读者。由于水平有限,不当之处恳请赐教。

作 者

2010 年 8 月







## 第一篇 数据仓库

<b>第 1 章 数据仓库基础</b>	<b>3</b>
1.1 引言	3
1.1.1 演变过程	3
1.1.2 定义	5
1.2 体系结构	6
1.2.1 两层的体系结构	6
1.2.2 三层的体系结构	8
1.3 组成	9
1.4 元数据	14
1.4.1 定义和分类	14
1.4.2 标准化	15
1.4.3 CWM	16
1.4.4 UML、MOF 和 XMI 与 CWM 的关系	20
1.5 数据粒度	22
1.6 数据模型	23
1.7 ETL	23
1.7.1 主要流程	24
1.7.2 数据抽取	24
1.7.3 数据转换	26
1.7.4 数据加载	27
<b>第 2 章 数据仓库设计和实现</b>	<b>29</b>
2.1 数据仓库设计	29
2.1.1 设计方法	31
2.1.2 体系结构设计	32
2.1.3 数据模型设计	34
2.2 ETL 设计	52
2.3 数据仓库实现	58



# 目 录

## 第 3 章 数据仓库实例 62

- 3.1 实例一 62
  - 3.1.1 选择主题 62
  - 3.1.2 逻辑模型设计 63
  - 3.1.3 物理模型设计 70
  - 3.1.4 ETL 设计 71
- 3.2 实例二 75
  - 3.2.1 总体结构设计 75
  - 3.2.2 概念模型设计 77
  - 3.2.3 逻辑模型设计 77
  - 3.2.4 物理模型设计 84
  - 3.2.5 数据清洗设计 86
  - 3.2.6 ETL 设计 86

## 第 4 章 OLAP 和 OLAM 93

- 4.1 OLAP 93
- 4.2 OLAM 97
  - 4.2.1 体系结构 98
  - 4.2.2 特点 99
  - 4.2.3 基于 Web 的 OLAM 100

## 第二篇 数 据 挖 掘

---

## 第 5 章 数据挖掘基础 105

- 5.1 概述 105
  - 5.1.1 定义 105
  - 5.1.2 功能 108
  - 5.1.3 模型 109
  - 5.1.4 展望 115
- 5.2 实现 117
- 5.3 工具 118



5.3.1	概述	118
5.3.2	比较	120
<b>第 6 章 聚类分析 123</b>		
6.1	硬聚类	124
6.1.1	算法种类	124
6.1.2	相似度计算	127
6.1.3	实现方法	129
6.1.4	主要算法	130
6.2	模糊聚类	143
6.2.1	概述	143
6.2.2	主要算法	146
6.3	评价	150
<b>第 7 章 分类和预测 155</b>		
7.1	神经网络	156
7.2	决策树	160
7.3	实现过程	165
<b>第 8 章 关联分析 167</b>		
8.1	概述	167
8.2	Apriori	170
8.3	FP-Growth	173
<b>第 9 章 Web 挖掘 176</b>		
9.1	概述	177
9.1.1	定义	177
9.1.2	自然语言理解	180
9.1.3	Web 挖掘过程	190
9.2	Web 文档抽取和表示	192
9.2.1	Web 文档抽取	192
9.2.2	Web 文档表示	192



# 目 录

9.3	特征提取	194
9.4	Web 聚类	196
9.5	Web 分类	198
9.5.1	朴素贝叶斯	199
9.5.2	其他方法	201
9.5.3	评价	201

## 第 10 章 数据挖掘实例 203

10.1	TOM 和 eTOM	203
10.2	客户细分	210
10.2.1	客户生命周期	211
10.2.2	客户价值	212
10.2.3	数据准备	214
10.2.4	分析过程	215
10.2.5	结果	220
10.3	重入网识别	222
10.3.1	定义	222
10.3.2	数据准备	222
10.3.3	分析过程	230
10.3.4	结果	232
10.4	WAP 日志挖掘	232
10.4.1	定义	233
10.4.2	数据准备	234
10.4.3	分析过程	238
10.4.4	结果	239

## 第三篇 语义网和本体

## 第 11 章 知识 243

11.1	概述	243
11.2	知识分类	247

11.3	知识表示	248
11.3.1	知识表示观	249
11.3.2	知识表示方法	251
11.4	知识管理	256
11.4.1	概述	256
11.4.2	知识管理与信息管理的关系	257
11.4.3	核心技术	258
第 12 章	语义网和本体	261
12.1	语义网	261
12.1.1	概述	261
12.1.2	层次结构	265
12.1.3	元数据	267
12.1.4	核心技术	269
12.1.5	开发工具 Jena	272
12.1.6	Web 3.0	272
12.2	本体	274
12.2.1	哲学本源	274
12.2.2	定义	275
12.2.3	建模	275
12.2.4	分类	276
12.2.5	构建方法	276
12.2.6	描述语言	279
12.2.7	实例	281
参考文献		288



# 第 一 篇

## 数 据 仓 库

- 第1章 数据仓库基础
- 第2章 数据仓库设计和实现
- 第3章 数据仓库实例
- 第4章 OLAP和OLAM





# 第1章 数据仓库基础

## 1.1 引言

进入信息时代以来,特别是近些年,数据库规模日益扩大,数据呈爆炸性增长。图灵奖获得者吉姆·格雷提出了一个经验定律,即网络环境下每18个月产生的数据量等于有史以来的数据量之和,仅仅依靠数据库管理系统的查询检索机制和统计分析方法,已经远远不能满足实际需求,面临着“数据爆炸,知识匮乏”的严峻挑战。例如股票经纪人需要从日积月累的大量股票行情变化的历史记录(数据)中发现其规律以预测未来的趋势;天文学家需要从获取的观测数据(其规模可达数千吉字节)中发现新的遥远天体及其运动规律;医生需要从大量病人电子病历中发现某种疾病的起因、症状等。这些数据的共同特点是:其一数据量巨大,一般都是GB级乃至TB级;其二都以结构化的形式存储在数据库中,包含了大量潜在、有价值的知识,有的已被发现,有的还未被发现。如何有效地管理和利用数据库中的海量数据,以及如何发现其中潜在的知识,需要一种新的、更为有效的手段对各种数据源进行整合并挖掘以发现新知识,更好地发挥这些数据的潜能。因此,数据仓库(Data Warehouse, DW)和数据挖掘(Data Mining, DM)技术应运而生。

数据仓库是一个可更好地支持企业或组织决策,面向主题的、集成的、相对稳定的、随时时间不断变化的数据集合;数据挖掘则是使用计算机对大量数据进行快速、有效地分析和处理,从中提取知识,并以一种形式化的、可以理解的方式表达,以便于决策的过程。目前,数据仓库和数据挖掘技术已经成为计算机领域的研究热点之一,引起了数据库、机器学习、统计分析等领域专家的广泛关注。

### 1.1.1 演变过程

数据仓库是建立在传统事务型数据库的基础之上,为企业决策支持系统(Decision Support System, DSS)及数据挖掘系统提供数据源。到目前为止,国外数据仓库已经发展了十几年的时间,国内虽然起步较晚,但发展较为迅速。目前已有众多的大型公司或企业正在建或计划建设不同规模的数据仓库。

传统数据库(普通数据库)和数据仓库最根本的区别在于其侧重点的不同。数据处理分为事务型处理又称联机事务处理(Online Transaction Processing, OLTP)和分析型处理又称联机分析处理(Online Analytical Processing, OLAP)两大类。事务型处理以传统的数据库为中心进行企业日常的业务处理;分析型处理以数据仓库为中心分析数据背后的关联和规律,为企业的决策提供可靠、有效的依据。事务型处理和分析型处理的分离,划清了数据处理的分析型环境与事务型环境之间的界限。从而由原来以单一数据库为中心的数据环境演变为以数据库为中心的事务处理系统和以数据仓库为基础的分析处理系统。企业的生产环境也从以数据库为中心发展为以数据库和数据仓库为中心。因此,在事务处理环境中直



接构建分析处理应用是不合适的,要提高分析和决策的效率和有效性,分析型处理及其数据必须与操作型处理及其数据相分离,必须把分析型数据从事务处理环境中提取出来,按照决策支持的需要重新组织,建立单独的分析处理环境,数据仓库正是为了构建这种新的分析处理环境而出现的一种数据存储和组织技术。

传统数据库的主要任务是进行事务处理,所关注的是事务处理的及时性、完整性和正确性,在数据分析方面则存在着诸多不足,主要体现在缺乏集成性、主题不明确等多个方面。

1. 缺乏集成性

首先,企业数据库系统与部门条块分割,导致数据分布的分散化与无序化。在一个企业内部,生产、销售和财务等部门往往各自使用一套满足自身工作需要的应用程序。各个部门的应用系统往往不能数据共享,缺乏数据的统一管理和维护。这样企业内部尽管拥有的数据量极大,但各自封闭,构成相互独立的所谓“信息孤岛群”,无法形成统一体。其次,业务数据库缺乏统一的定义与口径,导致数据定义存在歧义。

2. 主题不明确

建立传统数据库的目的是为了满足事务处理的需要,数据库和表的定义与设计完全以此为基础。而对于数据分析而言,这些库和表无疑缺少明确的主题。

3. 分析处理效率低

设计基于传统数据库的应用系统的核心准则是保证事务处理及时而准确。显然,对处理大量分析型数据的效率无法保证。

数据仓库是因为用户需求增加而对某一类数据库应用范围的界定。仅从数据存储容器的角度而言,数据仓库与数据库并没有本质的区别。而且很多时候,数据仓库是作为一个数据库应用系统来看待的。因此,不应该说数据库到数据仓库是技术的进步。

通常,数据仓库是在传统数据库的基础上发展起来的,建立在异构的业务数据库基础上。尽管传统数据库对处理分析型数据存在缺陷,但数据仓库并不是对数据库的彻底抛弃。两者存在诸多差别,如表 1.1 所示。

表 1.1 数据库与数据仓库的比较

	数据库	数据仓库
内容	与业务相关的数据	与决策相关的信息
数据模型	关系、层次结构	关系、多维结构
访问	经常是随机地读、写操作	经常是只读操作
负载	事务处理量大,但每个事务涉及的记录数很少	查询量小,但每次需要查询大量的记录
事务输出	一般很少	可能非常大
停机	可能意味着灾难性错误	可能意味着延迟决策



从数据库到数据仓库演变的具体过程如图 1.1 所示。

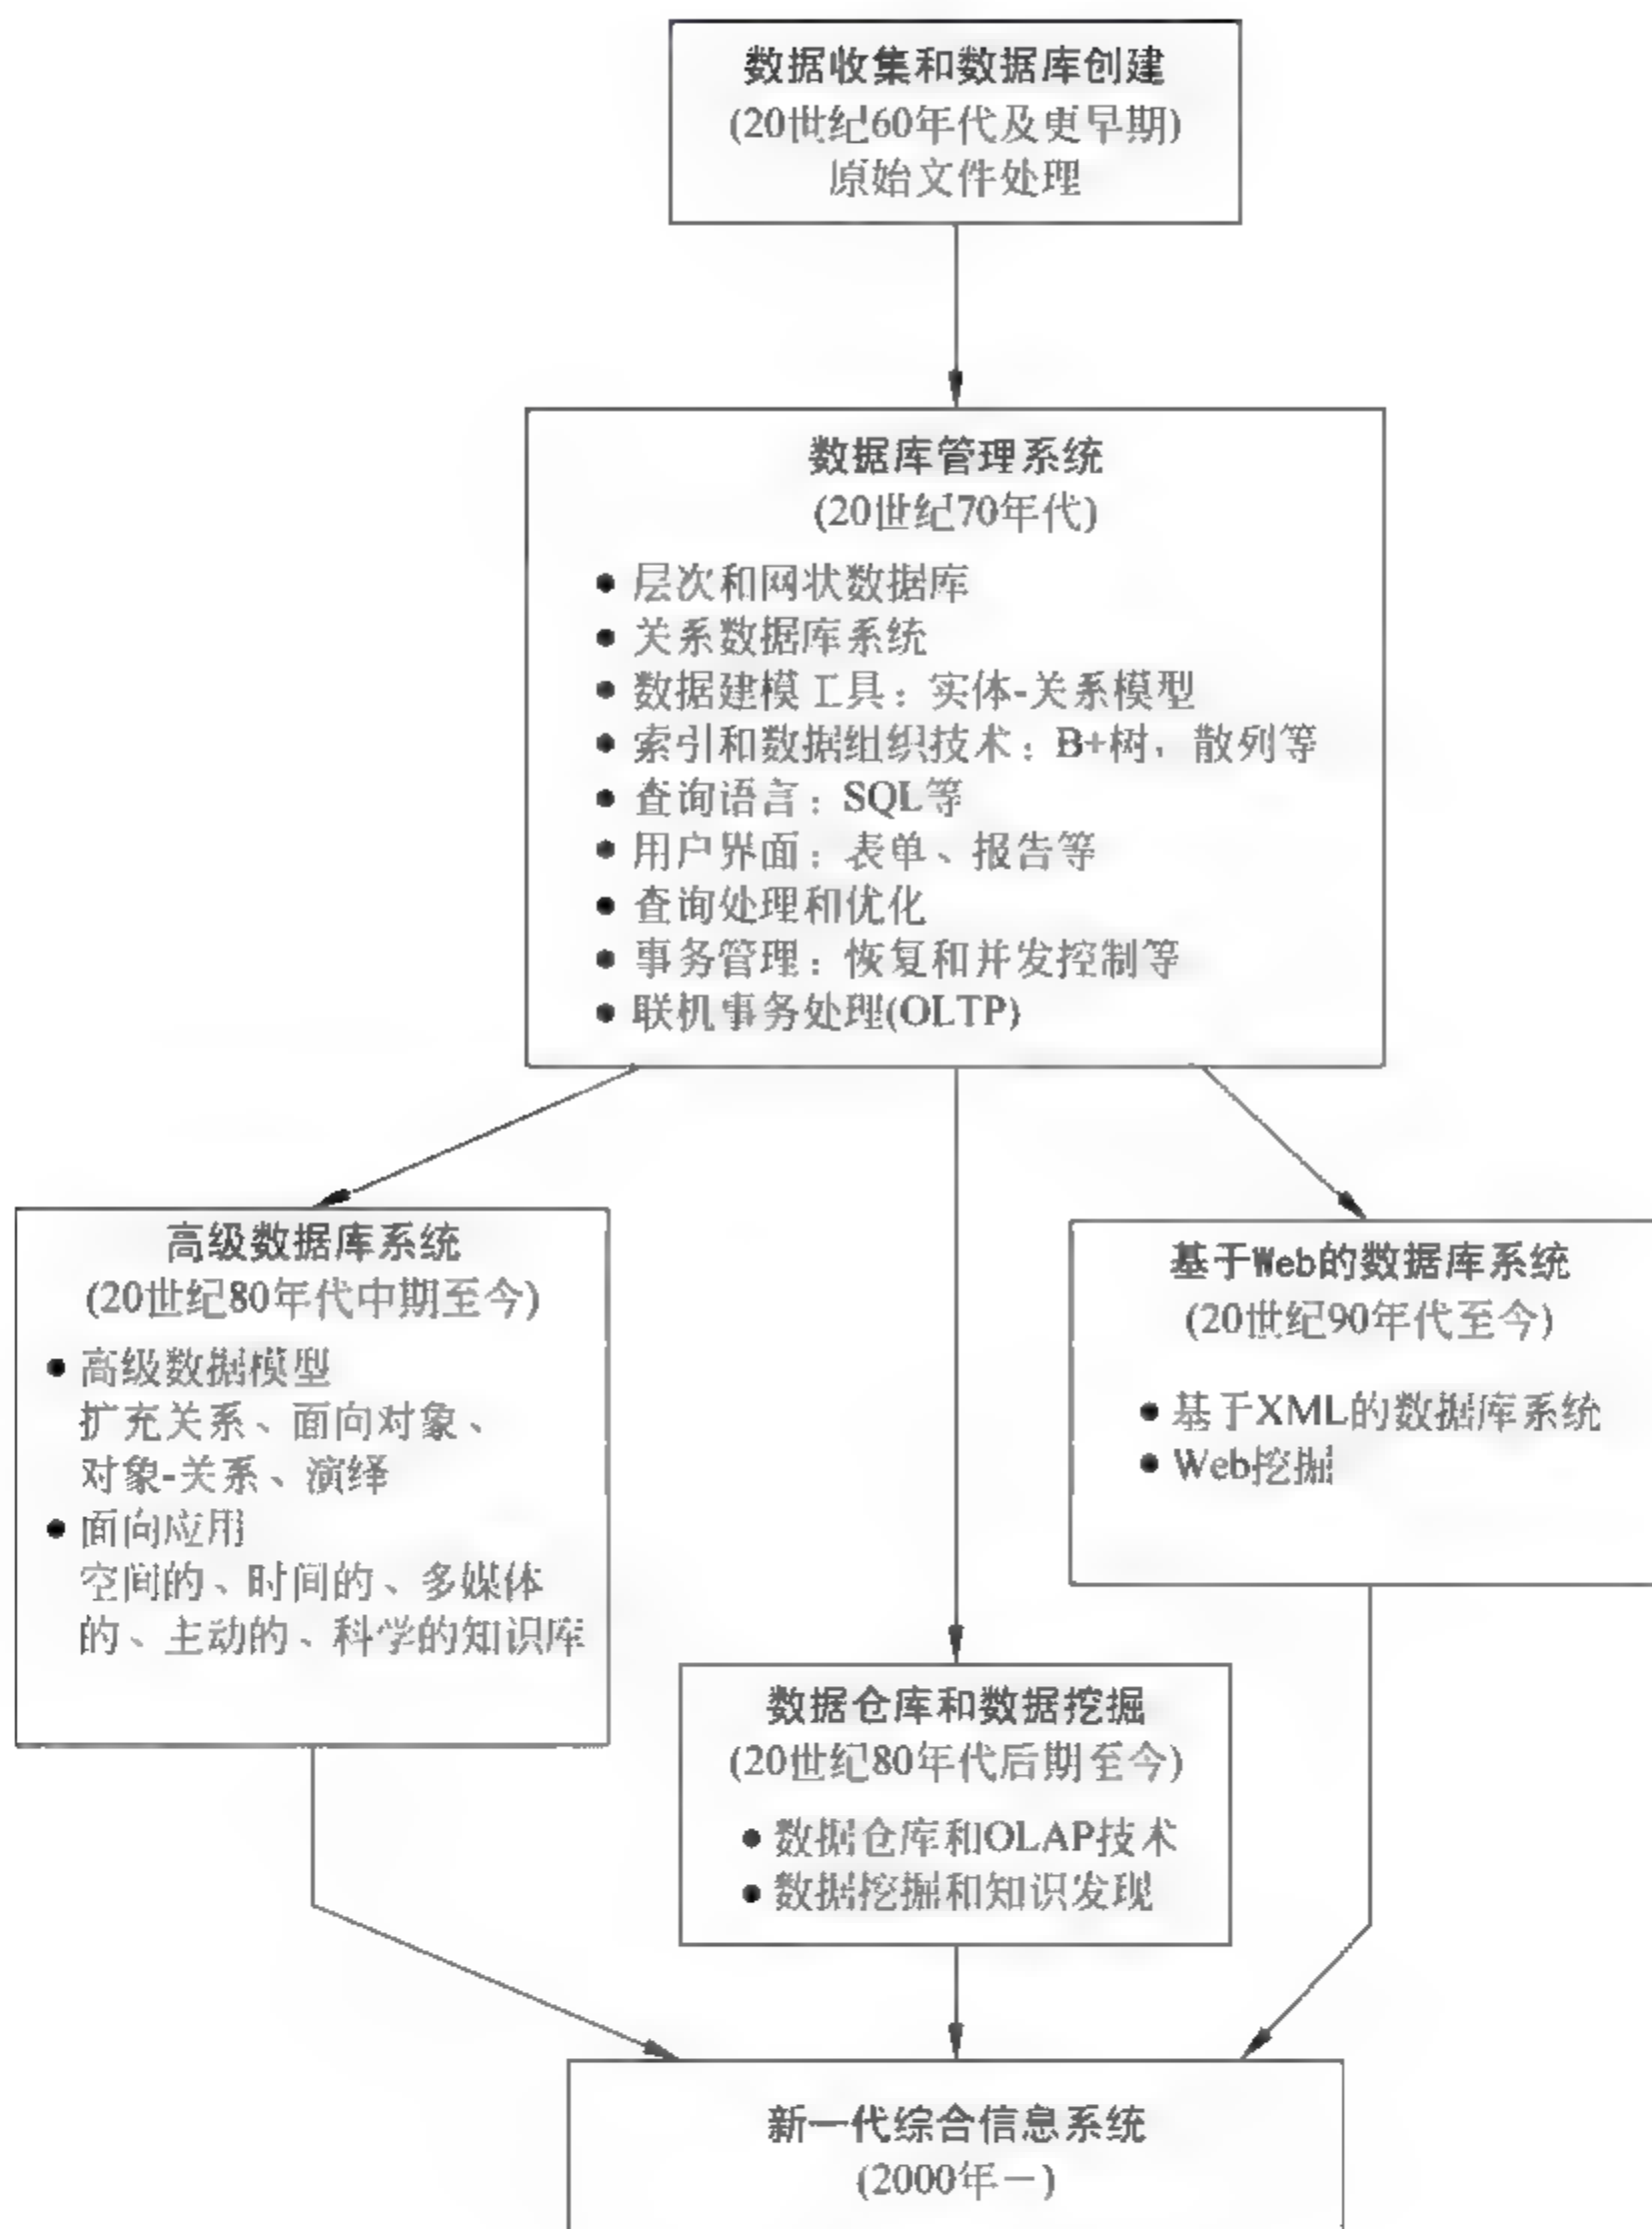


图 1.1 数据库到数据仓库的演变过程

### 1.1.2 定义

数据仓库的概念最早出现于 20 世纪 80 年代。1993 年,被称为“数据仓库之父”的 William H. Inmon 首次系统地阐述了数据仓库定义,即一个面向主题的、集成的、不可修改的且随时间变化的数据集合,以支持管理人员的决策。

面向主题是相对于传统数据库的面向应用而言。所谓面向应用是指系统实现过程中主要围绕一些应用或功能,而面向主题则是考虑一个个的问题域,对问题域涉及的数据和分析数据所采用的功能给予同样的重视。数据仓库是面向在数据模型中已定义业务的主要主

题域的,例如在电信领域中典型的主题域包括客户、产品、资源、渠道、服务和竞争等。

集成是指数据仓库中的数据来自不同的数据源。由于历史的原因,各数据源的组织结构往往不同,在这些异构的数据导入到数据仓库之前,必须经过一个集成过程。在数据仓库的所有特点中这是最重要的。应用系统的设计人员历经多年制定出来的不同的设计策略有很多种不同的表示方法,在编码、命名习惯、属性和属性度量等方面往往是不一致的。当数据导入数据仓库时,需要采用某种方法来消除应用系统中存在的不一致性。例如,对“客户性别”编码时,在数据仓库中编码为“男/女”或是 m/f 并不重要,重要的是无论使用什么原始应用系统,在数据仓库中都应该有一致的编码。如果应用系统中编码为 X/Y,则在其导入数据仓库时就应进行转换。对所有的应用都要考虑一致性,如命名习惯、键码结构、属性度量以及数据特点等。

与面向应用的事务数据库需要对数据进行频繁地插入、更新操作不同的是,数据仓库中数据的操作仅限于数据的初始导入和记录查询,而不能修改。数据库处理数据时,一般是一次访问和处理一条记录,也可以对操作型数据进行更新。但数据仓库中的数据通常是一起载入与访问,在数据仓库中并不进行一般意义上的数据更新。

随时间变化是指数据仓库以维的形式对数据进行组织,时间维是数据仓库中很重要的维度之一,并且数据仓库中数据的时间跨度较大,从几年甚至到几十年,称之为历史数据。数据仓库中数据随时间变化的特性表现在以下几个方面:

(1) 数据仓库中数据的时间期限要远远长于操作型数据库中数据的时间期限。操作型数据库中数据的时间期限一般是 60~90 天,而数据仓库中数据的时间期限通常是 5~10 年。

(2) 操作型数据库含有“当前值”的数据,这些数据的准确性在访问时是有效的,同样当前值的数据可被更新。而数据仓库中的数据仅仅是一系列某一时刻生成的复杂快照。

(3) 操作型数据的键码结构可能包含也可能不包含时间元素,如年、月和日等,而数据仓库的键码结构总是包含某一时间元素。

数据仓库是 DSS 的基础。因为在数据仓库中只有单一集成的数据源,并且数据是可访问的。与传统数据库相比,在数据仓库中 DSS 分析人员的工作将容易得多。

## 1.2 体系结构

### 1.2.1 两层的体系结构

由数据仓库的定义可知,它是将企业各个业务系统中与分析有关的数据集成在一起,同时数据仓库面向的应用是分析型操作,因此形成了 DB DW 两层的数据仓库体系结构,如图 1.2 所示。

其中,业务系统作为主要的分析数据来源,其数据格式主要是表的形式。实际中,由于要保证不影响业务系统的正常运行,一般不直接在业务系统中进行数据的查询和抽取,而是采取备份库或者文件传输的形式进行数据仓库的数据抽取。外部数据源是指信息来源于企业的外部,描述企业运营的外部环境与企业经营分析有关的数据,如各个企业的市场份额等,外部数据作为经营分析的补充,对企业经营决策的正确性起着十分重要的作用,因此应保证外部数据的实时性和准确性。外部数据源具有多样性的特点,如年报等都可以作为外



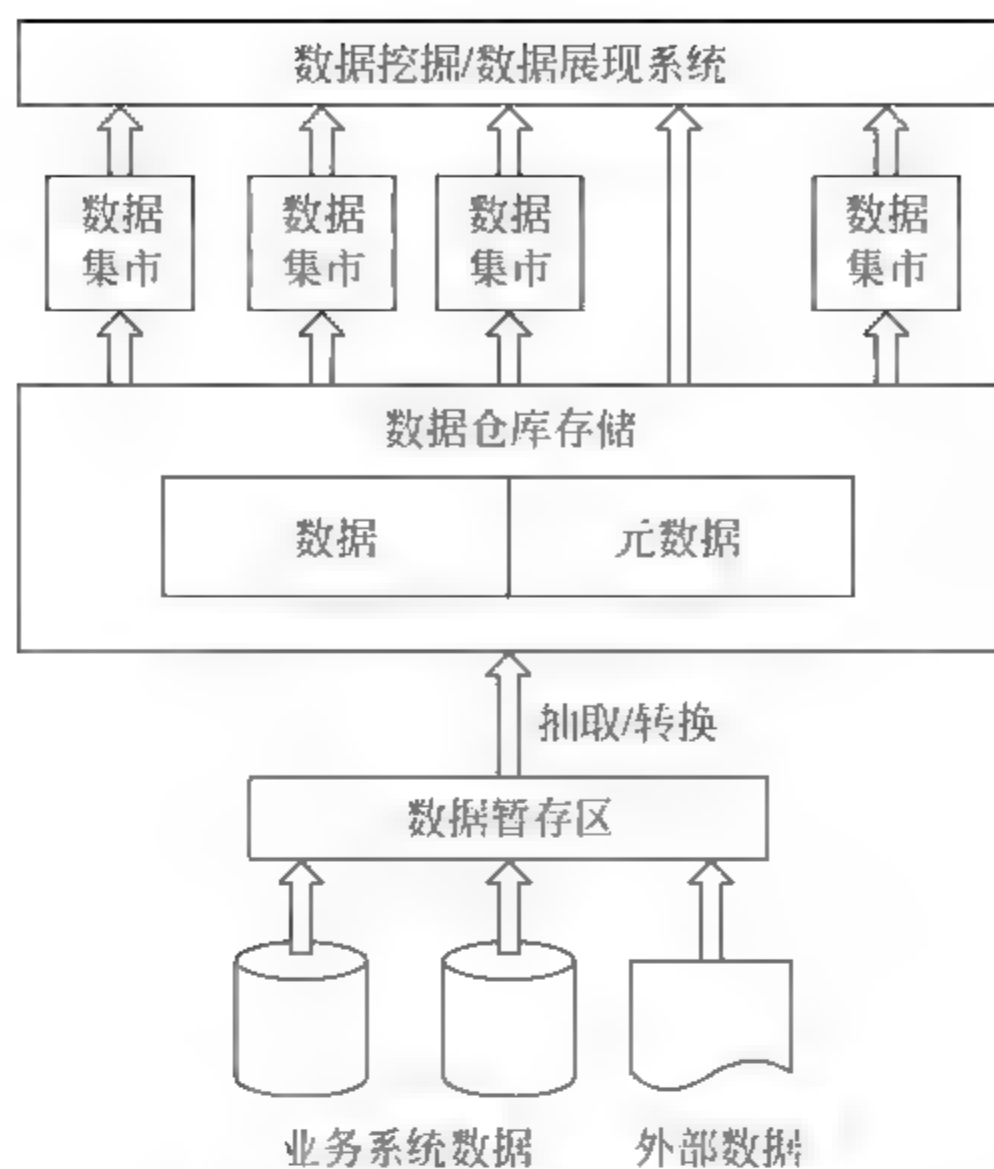


图 1.2 DB-DW 的两层体系结构

部数据源,同时外部数据源的格式也不统一,如文本、数据表格、图像和声音等。因此对外部数据源及其数据格式等都应在数据仓库的元数据中进行记录,同时元数据中还应对外部数据的可信程度有一定评价。

由于数据仓库的数据源不统一,同时源数据的存储形式也不相同,因此有必要在数据进入数据仓库前先将数据存放在一个统一的暂存区中,引入数据暂存区的主要作用如下:

(1) 统一不同数据源的数据格式。将不同数据源中不同的数据格式转换成统一的数据格式,供数据仓库统一处理。

(2) 进行数据的初步检查。在数据进入数据仓库之前,先对数据进行初步检查,鉴于不影响数据仓库的处理时间,这里的检查将仅涉及比较粗略的数据检查,如记录数量、关键字段是否丢失等,对于错误的数 据暂不导入数据仓库,这样对进入数据仓库的数据质量有一定保证,但是更复杂的数据清洁工作,如字段格式的统一以及数据内容的清洗这种单一记录级的处理工作则应该在数据抽取时完成。

数据暂存区可以多种存储形式实现,如文件目录或者数据库表的形式。

数据仓库中保存了大量的历史数据,同时数据仓库面向的是整个企业的分析应用,但在实际应用中不同部门的用户可能只使用其中一部分数据,从处理速度和效率的角度出发,可以将这部分数据在逻辑或者物理上进行分离,使用户无需到数据仓库的海量数据中进行查询,只在与本部门有关的数据集合上进行操作,这样就形成了数据集市(data mart)的概念,它是指面向企业的某个部门(主题)而在逻辑上或物理上划分出来的数据仓库的数据子集。将数据仓库按照数据的应用划分为多个数据集市,有利于数据仓库的负载均衡,保证应用的执行效率。同时,由于数据集市具有统一的数据来源——数据仓库,遵循统一的数据模型,保证了各个不同数据集市中数据的统一。



可以看出数据仓库体系结构是一种管道过滤器的结构,数据从数据源进入数据仓库到展示给最终用户,都有一定的关联关系,因此要保证数据仓库中数据处理的合理调度,则需要通过数据仓库的元数据完成。

### 1.2.2 三层的体系结构

数据仓库的提出使得操作型处理和分析型处理得以分离,从而形成了 DB-DW 两层的体系结构,但是在企业的业务处理中存在介于操作型和分析型之间的需求,需要对短期的历史数据进行分析,同时要求较快的响应速度,这种分析无法在操作型数据库中完成,因为其保存的是数据的瞬态信息,如果通过数据仓库完成,由于数据仓库保存了大量的历史数据,在响应时间上无法满足要求,因此提出了操作型数据存储(Operational Data Store, ODS)的概念,ODS 数据可以概括为面向主题的、集成的、可变的和当前的或接近当前的数据。其中,面向主题和集成的特点与数据仓库的概念相似;“可变的”是指 ODS 数据可以联机改变,包括增加、删除和更新等操作;“当前的”是指数据在存取时刻是最新的;而“接近当前”是指存取的数据是最近一段时间得到的。

面向主题和集成的特点使得 ODS 数据在静态特征上很接近数据仓库的数据,但是 ODS 和数据仓库之间存在重要的差别,主要体现在以下三个方面:

- (1) 数据的内容不同。数据仓库中历史数据是指长期保存并可重复查询的数据,既保存细节数据,也保存综合数据。而 ODS 一般只保存细节数据,而且 ODS 数据是可以更新的,即变化的,ODS 中保存的历史数据也是近期的。
- (2) 就数据量而言,ODS 保存的数据量要远远小于数据仓库的数据量。
- (3) 面向的应用不同。数据仓库用于长期的趋势分析或决策支持,而 ODS 主要是支持企业的全局 OLTP 和即时(up to the second)决策分析应用。

引入 ODS 后,原来 DB DW 的两层体系结构被扩展为 DB ODS DW 的三层体系结构,如图 1.3 所示。

在 DB-ODS-DW 三层体系结构中,ODS 的作用可以概括为:

- (1) 为数据仓库提供数据,减少数据仓库数据抽取的复杂性。由 ODS 的定义可知,它具有面向主题和集成两个特点,因此来自业务系统的源数据首先进入 ODS,在进入 ODS 时完成数据清洁和集成的工作,这样再向数据仓库提供的数据就是清洁的和统一的,减轻了数据仓库中数据抽取的工作量。
- (2) 即时的 OLAP 分析。由于在业务系统中需要对近期或当前的数据进行分析,如果该任务放在数据仓库中完成,由于数据仓库相应的处理环节较多,同时数据仓库保存了大量的历史数据,如果要完成这种需求势必造成留给数据仓库的数据处理时间减少,所以将这部分任务分配给 ODS,由于 ODS 保存了近期的数据,可以完成用户的即时分析需求。
- (3) 全局的 OLTP 操作。由于 ODS 数据的集成性,整合了企业中不同业务系统的数据,同时 ODS 数据是可更新的,因此 ODS 可以提供面向企业全局的 OLTP 操作。

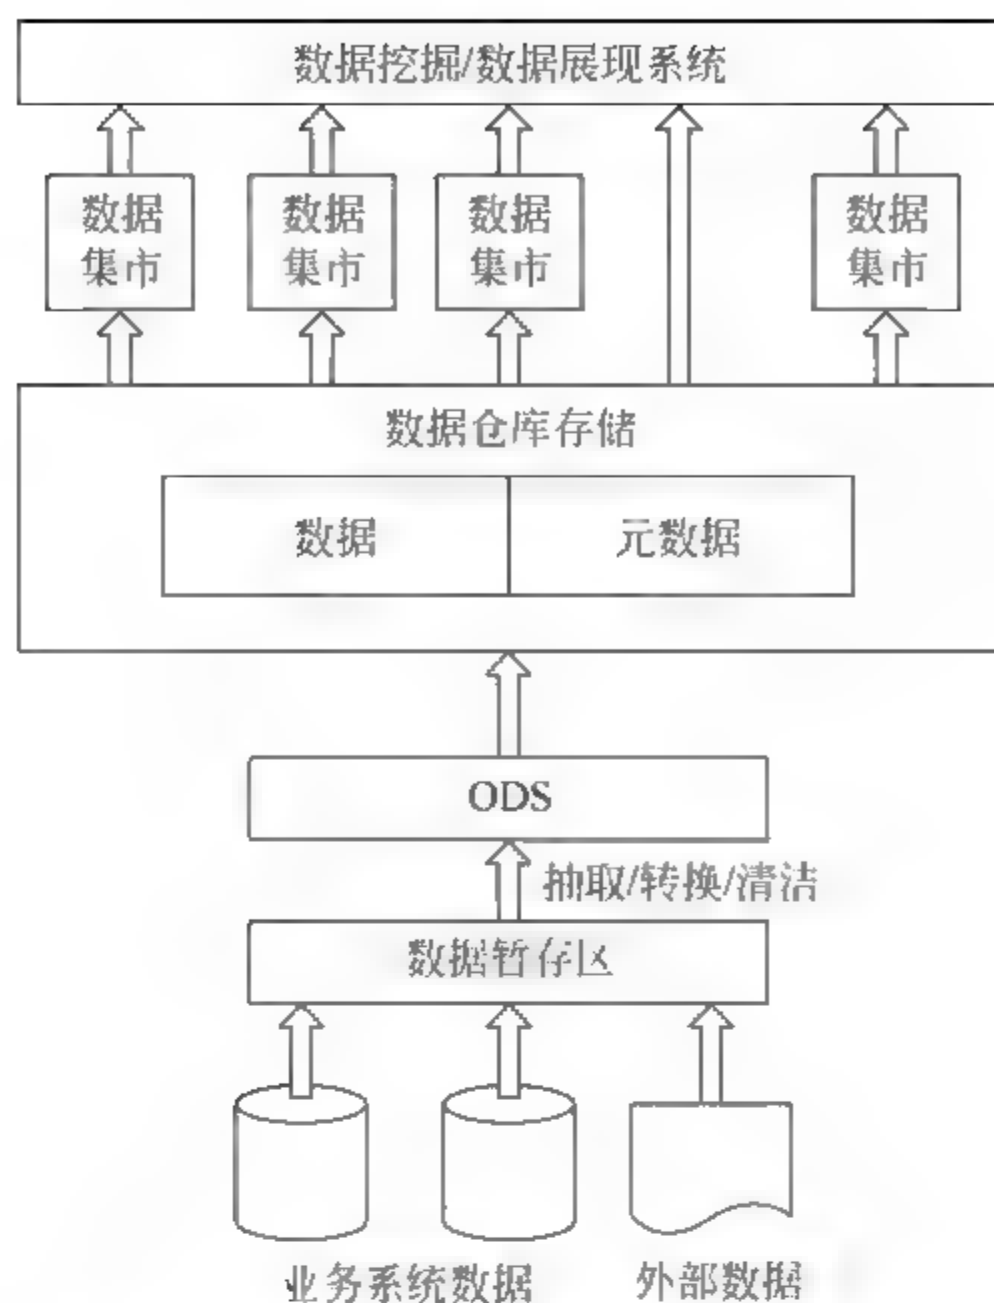


图 1.3 DB-ODS-DW 的三层体系结构

### 1.3 组成

数据仓库的容量一般都是在 100GB 以上。传统的关系型数据库是针对 OLTP 的，并不适用于数据量大且复杂度高的数据仓库。因此，数据仓库系统必须满足：

- 扩充数据仓库的数据。
- 每日对数据仓库系统的管理和维护。
- 允许客户增加需求。

要充分满足上述三点并不容易，尤其是数据仓库最终以自动的数据分析处理为目标。扩充数据仓库数据是非常重要的，其重点是抽取、整理并转换数据以及以适当的方式展现给用户分析使用。数据仓库并不是一个只读系统，虽然说事实数据导入数据仓库之后就不会再更新，但是如果客户需求改变，例如希望以不同的方式浏览相同的分析结果，则仍然会修订索引数据。每日对数据仓库系统的管理和维护与传统的 OLTP 系统完全不同，因为数据仓库的数据量远比 OLTP 系统大得多，所以需要更积极的管理方式。例如添加或删除数据，将数据仓库数据存入备存介质，由备存介质加载数据等。因此可以这样理解，数据仓库是一个持续更新的系统，以满足客户新的管理决策需求。允许客户增加需求的能力似乎是设计数据仓库系统时最困难的工作，因为每个客户都有各种不同的需求。数据仓库除了能够允许更新现有的需求外，还应该可以增加新的分析主题。

数据仓库系统应该具有以下功能：

- 抽取数据与加载数据。
- 整理并转换数据为一种数据仓库适用的格式。
- 备份与备存数据。



- 管理所有的查询,将它们导向适当的数据源。

数据仓库系统的组成如图 1.4 所示,其中包括数据、信息和知识三个层次。

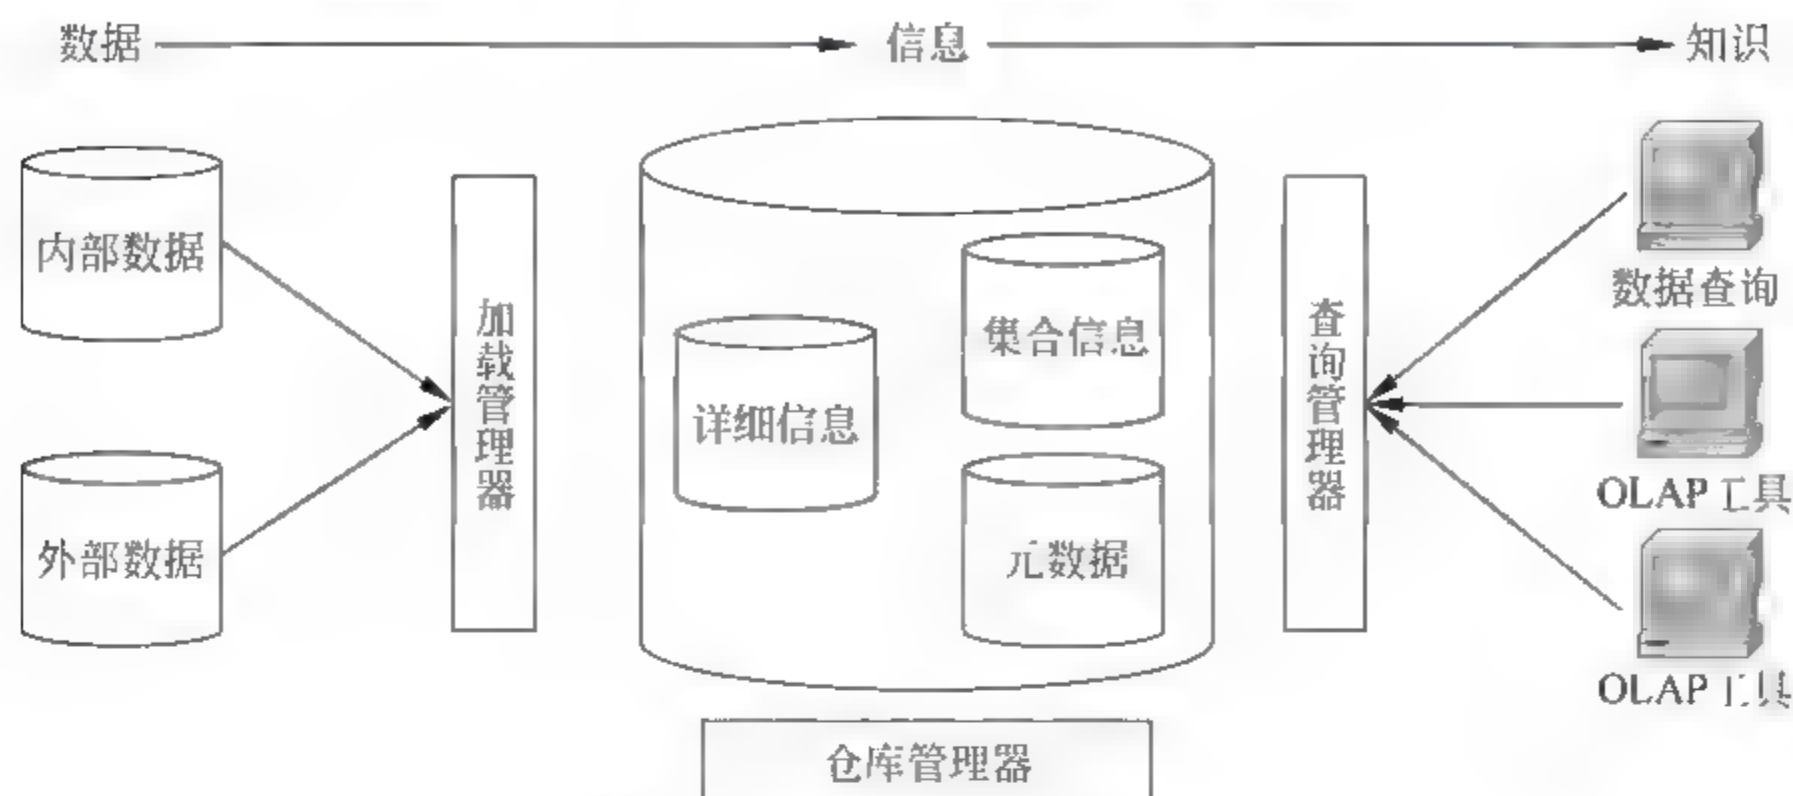


图 1.4 数据仓库系统的组成

数据仓库系统的管理器一般可细分为三种。

- 加载管理器：抽取并加载数据,在加载数据之前与过程中执行简单的转换。
- 仓库管理器：转换并管理数据仓库数据,备份与备存数据。
- 查询管理器：引导并管理数据仓库的查询。

#### 1. 加载管理器

加载管理器主要是支持数据的抽取和加载,可以由一些外购的软件工具、针对特殊需要而编写的程序、存储过程以及脚本文件组成。用户可以尽量选用适合的软件工具协助进行整个加载管理工作,但是因为加载管理器是每个数据仓库中功能最无法正规化的部分,会因原始数据的特性而存在很大差异,所以不可能完全使用外购的软件工具,必须自行设计针对特殊需要而编写程序、存储过程或脚本文件。

加载管理器应该具备以下功能：

- 自源系统抽取数据。
- 将抽取的数据快速加载到临时存储介质。
- 执行简单的数据转换。
- 将转换后的数据加载至与数据仓库类似的数据结构之中。

加载管理器的构成如图 1.5 所示。

上述所有功能都应能自动执行,至于数据错误修正部分,也应该尽量避免人工介入。

每一种关系数据库产品都会提供数据快速加载工具,至于数据拷贝管理工具则会提供某种转换功能。如果数据源需要比较复杂的转换,可以自行使用 C/C++ 或存储过程编写转换程序,至于工作控制流程则可以使用操作系统提供的功能或编写控制用的脚本文件。

因为数据仓库的数据量非常庞大,所以需要快速的加载工具。一般而言,可以将原始数据先加载到关系数据库,然后再进行数据验证。

当原始数据已经导入临时存储介质后,可以利用数据库本身的功能与外购的软件工具进行简单的转换,这些转换不包括复杂的逻辑运算也不会使用到关联操作。当简单的数据

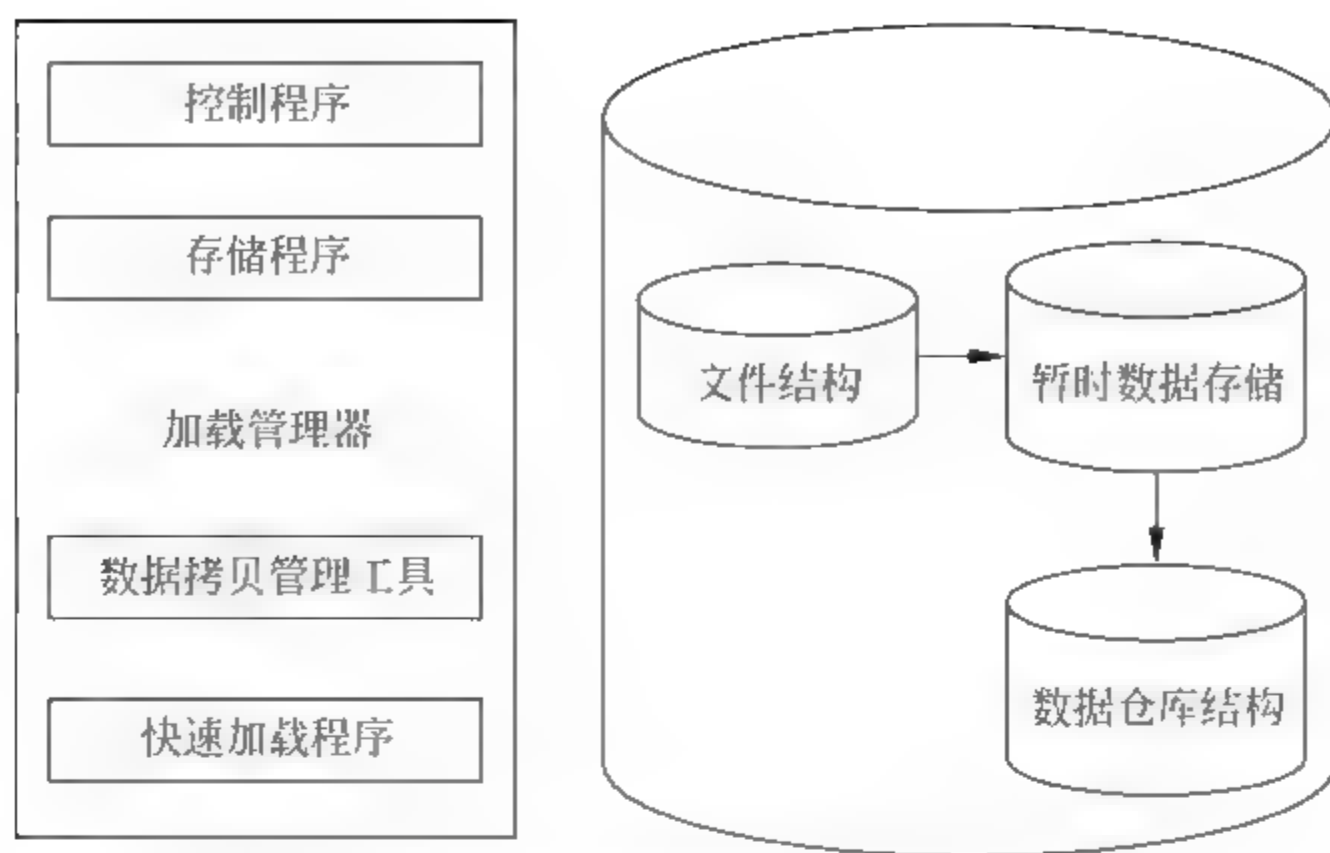


图 1.5 加载管理器的构成

转换执行完毕,可以使用自行设计的软件工具进行与数据仓库相关以及较复杂的转换。下面列出了一些可以在本阶段执行的数据转换与检验功能:

- 删除在数据仓库中不必要的字段。
- 将所有的数值转换为所需的数据类型。
- 将每个字段转换为正确的格式(例如删除前置空格符等)。
- 根据企业需求校验字段值是否有效。
- 检验数据仓库所需字段是否有数据。

## 2. 仓库管理器

仓库管理器执行管理一个数据仓库所有的必要程序,可以由一些外购的系统管理工具、针对特殊需要而编写的程序及脚本文件组成,仓库管理器的复杂度因自动化的程度而异。仓库管理器的构成如图 1.6 所示。

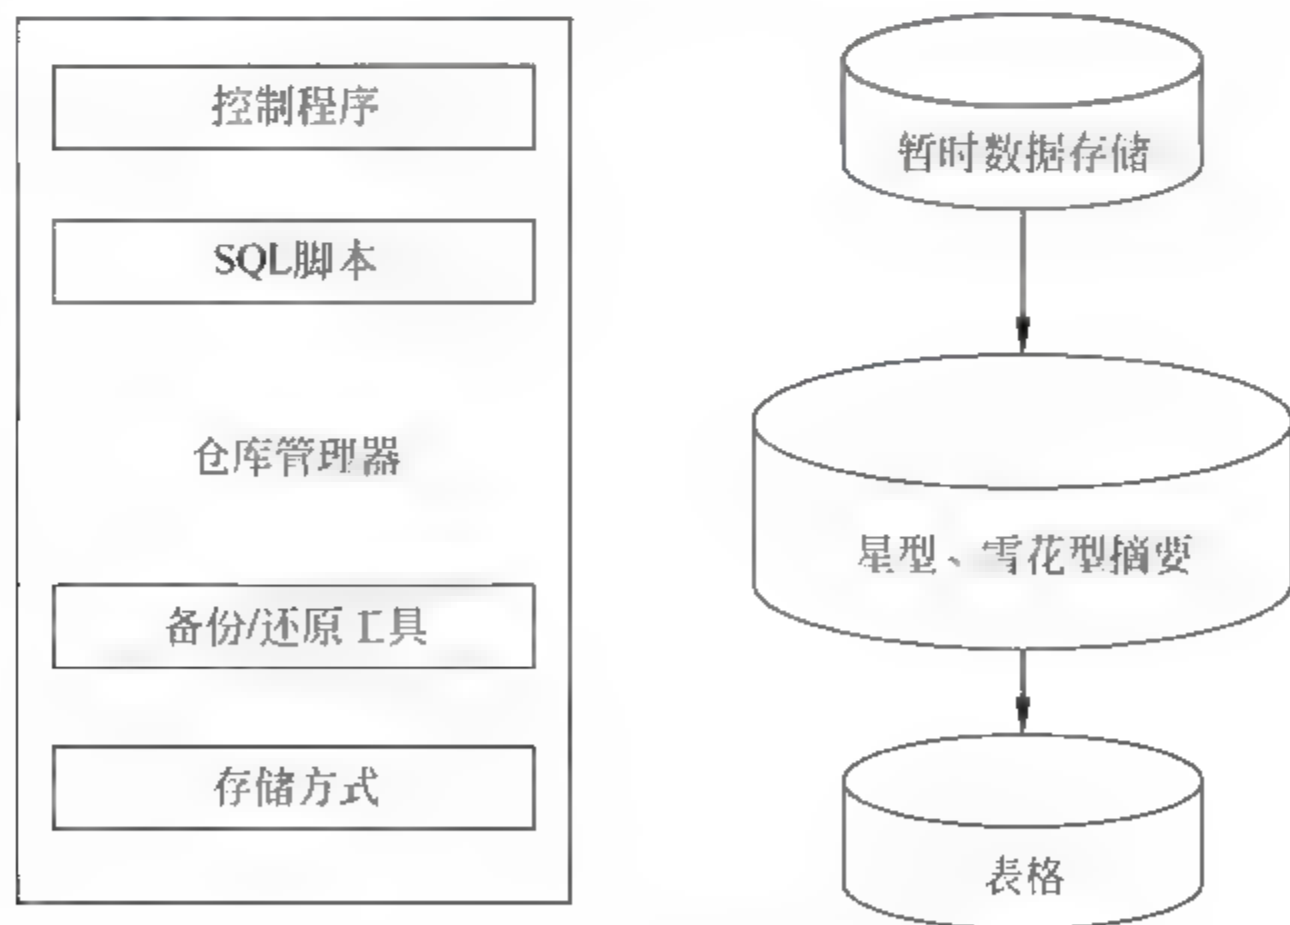


图 1.6 仓库管理器的构成

仓库管理器执行以下功能:

- 检验各字段相互之间的关系与一致性。



- 将临时存储介质中的数据进行转换与合并,然后加载到数据仓库。
- 对数据仓库数据添加索引、视图和数据分区。
- 根据需要将数据进行正规化。
- 根据需要生成新的集合信息。
- 更新已有的集合信息。
- 备份数据仓库(完整或递增式)。
- 备存数据仓库中过时的数据(移存至其他存储介质)。

用户可以使用 C/C++ 或存储过程将数据导入到数据仓库,添加索引、视图和数据分区,生成星型、雪花型数据架构,生成、更新集合信息;可以使用操作系统与数据库管理系统提供的工具备份数据仓库、备存过时数据;也可以使用数据仓库系统提供的分析工具分析查询概述文件。

在数据仓库中可以将数据分为若干个数据分区,以便于管理。用户可以根据数据仓库中数据的更新频率创建数据分区,如果数据仓库周期以季度为单位,则可以在每一季度结束后将加入的历史数据创建成以季度为单位的数据分区,而且可以定期将小的数据分区并入大的数据分区。

将原始数据整理、检验完毕后,仓库管理器会把数据转换为一种适用于查询管理决策信息的数据结构。

数据仓库的数据是由事实数据与维度数据组成的,事实数据是能够反应过去事实的数据,而维度数据则是为了使查询更加快速而创建的索引参考数据。就数据仓库的数据结构而言,是以事实表为中心,各个维表位于四周而形成的一个星型模式。为了便于快速查询,仓库管理器会为事实表和维表创建索引。事实表拥有非常多的记录,当索引文件大到一定程度时,将索引以一笔一笔的方式添加至已有的索引,不见得是一种好方法。如果事实表包含了很多记录,建议先删除现存的索引,然后再重新创建索引,这样运行效率较高。维表的数据量虽然也不小,但是比起事实表还是小得多。一般而言,维表不会做太多的更新,除非更新整个维表,一般不需要删除维度数据再重新创建索引。出于管理方面的考虑,可以将事实数据划分为多个数据分区,但是对用户而言,数据分区则是完全透明的。为了使用户看到的是一个独立完整的事实表,仓库管理器创建一些视图将整个数据分区合并为一个单表。

若数据仓库周期以季度为单位,可以考虑创建以下视图:

- 为上半年创建一个视图。
- 为当年创建一个视图。
- 为上一年创建一个视图。

创建视图将降低查询的运行效率,所以建议在一个视图中不要包含过多的数据分区,而且不要创建多层视图。只要不创建包含过多数据分区的视图,系统都可以自行消化掉这些工作的开销。当数据已经完全加载了数据仓库的星型、雪花型架构后,仓库管理器将创建一系列的集合信息,以加快常用的一般性查询的运行速度。因为每个查询都是在抽取某一维度的部分数据集合,所以仓库管理器会以此为基础决定要计算哪些集合信息。例如上一季度的销售量、某一部门的销售量、上半年整个公司的销售量。

仓库管理器的重要任务之一是管理查询概述文件,为了统计数据仓库系统内常用的查询,查询管理器搜集所有的查询并加以统计分析,归纳出为哪些常用的查询创建集合信息。



查询概述文件在数据仓库中是一种元数据,主要描述一个数据仓库中所有查询的特性。当用户更新了其需求之后,仓库管理器将更新对应的查询概述文件,然后重新生成新的集合信息。可以使用存储过程或嵌入式C编写计算集合信息的应用程序。

一般的数据库管理系统都会提供搜集查询的功能,当仓库管理器由查询管理器搜集到足够的统计信息时,可以下面的方式执行集合信息的计算工作:

- 将SQL查询转换为星型查询。
- 分析星型查询,检查使用到哪些事实数据、维度数据和集合信息。
- 决定集合信息的使用频率(有多少个查询使用一项集合信息)。
- 检查目前的查询概述文件中是否已包含该项集合信息。
- 如果查询概述文件尚未包含该项集合信息,则将其定义加入。
- 定期检验不再适用的集合信息,并将其定义从查询概述文件中删除。
- 定期根据修正过的查询概述文件重新创建新的集合信息。

当然,仓库管理器不一定需要为查询概述文件中所有的项目创建集合信息,因为创建集合信息需要占用系统资源。如果数据仓库系统的资源有限,可以根据每项的使用频率设置优先级,从而仅为某些优先级足够高的项目计算集合信息。

### 3. 查询管理器

查询管理器执行管理数据仓库系统中所有查询的相关处理程序,可以由一些外购的查询工具、数据仓库系统所提供的系统监控工具、数据库管理系统所提供的管理工具、针对特殊需要而编写的程序以及脚本文件组成。同样地,查询管理器的复杂度视数据仓库系统而定。

查询管理器的构成如图1.7所示。

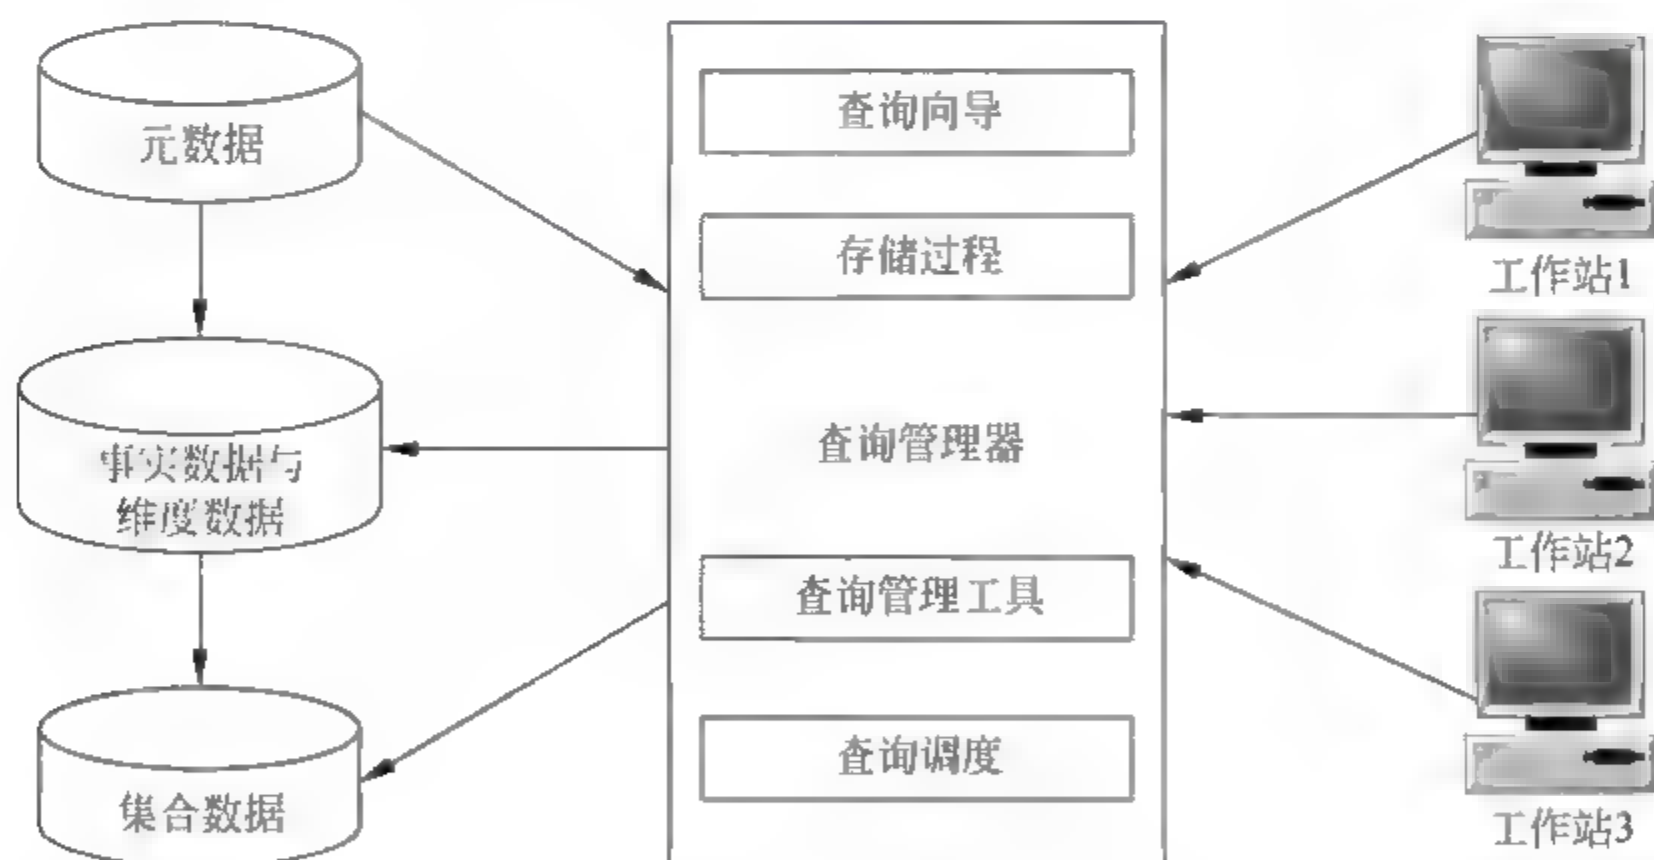


图 1.7 查询管理器的构成

查询管理器主要执行以下功能:

- 将查询引导至正确的表。
- 为所有的用户查询进行调度。

可以使用用户存取工具、存储过程、C/C++程序将查询引导至正确的表;也可以使用存取工具、存储过程、C/C++程序、数据库管理系统提供的管理工具、外购的调度软件为所有的用户查询进行调度。



查询管理器将查询统计分析的结果存入查询概述文件,供仓库管理器使用,以决定为哪些项目执行数据集合的工作。

## 1.4 元数据

### 1.4.1 定义和分类

元数据(metadata)是关于数据的数据。在数据仓库系统中,元数据可以帮助数据仓库管理员和数据仓库开发人员非常方便地找到所需的数据。元数据是描述数据仓库中数据结构和构建方法的数据。

随着计算机技术的应用日益广泛,元数据得到人们越来越多的关注,这是由多方面的需求决定的。

其一是管理数据的需求。当系统数据量越来越大,检索和使用这些数据的效率会降低,通过存储关于系统和数据的内容、组织、特性等细节可以帮助有效地管理,从而提高效率。

其二是系统分布、互通和重用的要求。目前信息系统一个共同的趋势是信息共享,要实现异构系统的信息共享,则需要描述数据语义以及软件开发过程的元数据,而且这些元数据必须标准化,以充分实现分布、互通和重用。

其三是元数据重用、综合的需求。目前,很少有单一工具能满足大型商业应用的需求,用户常常需要使用多种工具的组合,不同工具之间数据交换的途径之一就是标准的元数据。

在过去的几年里,元数据的概念在现实中大量使用,有时为了支持信息检索,有时为了软件配置,有时为了不同系统之间的数据交互。对于不同的领域专家,元数据有着不同的应用,但至少有两点是共同的,即元数据是对数据的描述;元数据的存在是为了更有效地使用数据。

对于元数据,根据观察角度的不同,可以划分为不同的类别。

按照与特定领域是否相关可划分为:

- (1) 与特定领域相关的元数据:描述数据在此特定领域内的公共属性。
- (2) 与特定领域无关的元数据:描述所有数据的公共属性。
- (3) 与模型相关的元数据:描述信息和元信息建模过程的数据。此类元数据又可分为以下两类:

① 横向模型关联元数据:综合现有的两个或多个信息模型,例如两个不同数据库之间的交互、从多个数据源中提取数据时,就需要这种横向模型元数据。当不同的信息模型之间进行互通时,需要模型中各个层的关联描述,即横向模型关联元数据。

② 纵向模型关联元数据:模型信息层与元信息层之间的关联元数据。不同的层可以采用不同的模型,上层是下层的结构描述,上下层之间对应关联,即纵向模型关联元数据。

(4) 其他元数据:例如系统硬件、软件描述和系统配置描述等。

按照元数据的应用场合可划分为:

(1) 数据元数据,又称为信息系统元数据。信息系统使用元数据描述信息源,以按照用户需求检索、存取和理解源信息。因此,元数据保证了在新的应用环境中使用信息,支持了



整个信息结构的演进。

(2) 过程元数据,又称为软件结构元数据。它是关于应用系统的信息,帮助用户查找、评估、存取和管理数据。大型软件结构中包括描述各个组件接口、功能和依赖关系的元数据,这些元数据保证了软件组件的灵活、动态配置。

按照元数据的具体内容可划分为:

- (1) 内容(content): 识别、定义、描述基本数据元素,包括数据单元、合法值域等。
- (2) 结构(structure): 在相关范围内定义数据元素的逻辑概念集合。
- (3) 表示(representation): 描述每一个值域(多为技术相关)的物理表示,以及数据元素集合的物理存储结构。
- (4) 文法(context): 提供基础数据的族系和属性评估,包括所有与基础数据的收集、处理和使用相关的信息。

元数据是数据仓库系统不可或缺的重要部分。按照用途的不同还可划分为技术元数据(technical metadata)和业务元数据(business metadata)两大类。技术元数据存储关于数据仓库系统技术细节的数据,是用于开发和管理数据仓库使用的数据,它保证了数据仓库系统的正常运行;业务元数据从业务角度描述数据仓库中的数据,它提供介于使用者和实际系统之间的语义层,使得数据仓库使用人员能够“读懂”数据仓库中的数据。

### 1.4.2 标准化

关于元数据的一般标准,就内容而言大致可分为两类:一是元数据建模,即对元数据的组织进行规范定义,使得在元数据建模的标准制定之后产生的元数据都以一致的方式组织,从而保证元数据管理的一致性和简单性;二是元数据交互,即对已有的元数据组织方式以及相互间交互格式进行规范定义,实现不同系统元数据的交互。目前,定义元数据相关规范的主要组织机构包括:

#### 1. 对象管理组织

1995年对象管理组织(Object Management Group,OMG)采用了MOF(Meta Object Facility,元对象工具)并不断完善;1997年采用了UML(Unified Modeling Language,统一建模语言);2000年又采用了CWM(Common Warehouse Metamodel,通用仓库元模型)。UML、MOF和CWM这三个标准形成了OMG建模和元数据管理、交换的基础,推动了元数据标准化的快速发展。

#### 2. 元数据联合会

元数据联合会(Meta Data Coalition,MDC)成立于1995年,旨在提供标准化的元数据交互。MDC于1996年开发了MDIS(Meta Data Interchange Specification)并完成MDC OIM的技术评审,MDC OIM基于微软的开放信息模型(Opening Information Model,OIM),是一个独立于技术的、以厂商为核心的信息模型。OIM是微软的元数据管理产品Microsoft Repository的一部分,由微软和其他二十多家公司共同开发,做为微软开放过程的一部分,经过三百多家公司评审。

为了推动元数据的标准化,MDC和OMG在元数据标准的制定上协同工作。1999年4月,MDC成为OMG的成员,而OMG也同时成为MDC的成员。MDC使用了OMG的



UML,而 MDC OIM 中的数据仓库部分被用来作为 OMG 的公共仓库元数据交互(Common Warehouse Metadata Interchange,CWMI)的设计参考。在两个组织技术力量的合作努力下,元数据标准将逐步实现标准化。

下面将重点介绍 CWM。

### 1.4.3 CWM

目前,数据仓库产品很多,它们对元数据都有自己的定义和格式,因此创建、管理和共享元数据很耗时而且容易出错。为了解决上述问题,必须采用标准的语言描述数据仓库元数据的结构和语义,并提供标准的元数据交换机制。

但是,元数据的交换涉及很多问题,例如元数据的表示形式以及交换机制等。为了解决上述问题,2000 年 OMG 提出一套关于数据仓库元数据的 CWM 规范,其主要目的是方便异构、分布式系统中的数据仓库工具、数据仓库平台以及元数据库之间的元数据交换,旨在推动数据仓库、商业智能和知识管理方面元数据的共享和交换。与 OMG 合作提出 CWM 规范的公司包括 IBM、Unisys、NCR、Hyperion Solutions、Oracle、UBS AG、Genesis Development、Dimension EDI 等,还有一些公司明确表示支持 CWM,包括 Sun、HP、Data Access Technologies、InLine Software、Aonix、Hitachi 等。

#### 1. 提出的背景

提出 CWM 的主要原因在于:

- (1) 从数据仓库开发者的角度而言,单一工具很少能完全满足用户不断变化的需求,但同时又很难对各种产品进行集成;
- (2) 从数据仓库用户的角度而言,面对的信息量太大,无法轻易找到真正所需的信息,而且把这些信息完整正确地表示出来也是一个挑战;
- (3) 从数据仓库供应商的角度而言,目前信息的共享还没有标准格式,元数据集成的代价太大。

#### 2. 基础

CWM 主要基于以下三个工业标准,即:

- (1) UML 是 OMG 的一个建模标准。
- (2) MOF 是 OMG 关于元模型和元数据库的一个标准。
- (3) XMI(XML Metadata Interchange,XML 元数据交换)是 OMG 关于元数据交换的标准。

这三个标准是 OMG 元数据库体系结构的核心,UML 定义了表示模型和元模型的语法和语义;MOF 为构建模型和元模型提供可扩展的框架,并提供存取元数据的程序接口;而利用 XMI 则可以将元数据转换为标准的 XML 数据流或文件格式,便于交换,这大大增强了 CWM 的通用性。

#### 3. 层次

为了说明 CWM 和这三个标准之间的关系,首先介绍一下元数据的层次。传统的元数据包括四个层次,除了最底层外,每一层都对其下一层进行描述。最底层是用户对象层(M0),包括用户描述的信息,这些信息统称为数据;上一层是模型层(M1),由描述信息的元数据组成,在这一层元数据一般都组合成模型的形式;再上一层是元模型层(M2),由定



义 M1 层元数据格式和语义的描述信息组成,即元元数据,一般组合成元模型的形式。最高层是元元模型层(M3),它定义元模型的结构和语义。四层结构的实例如图 1.8 所示。

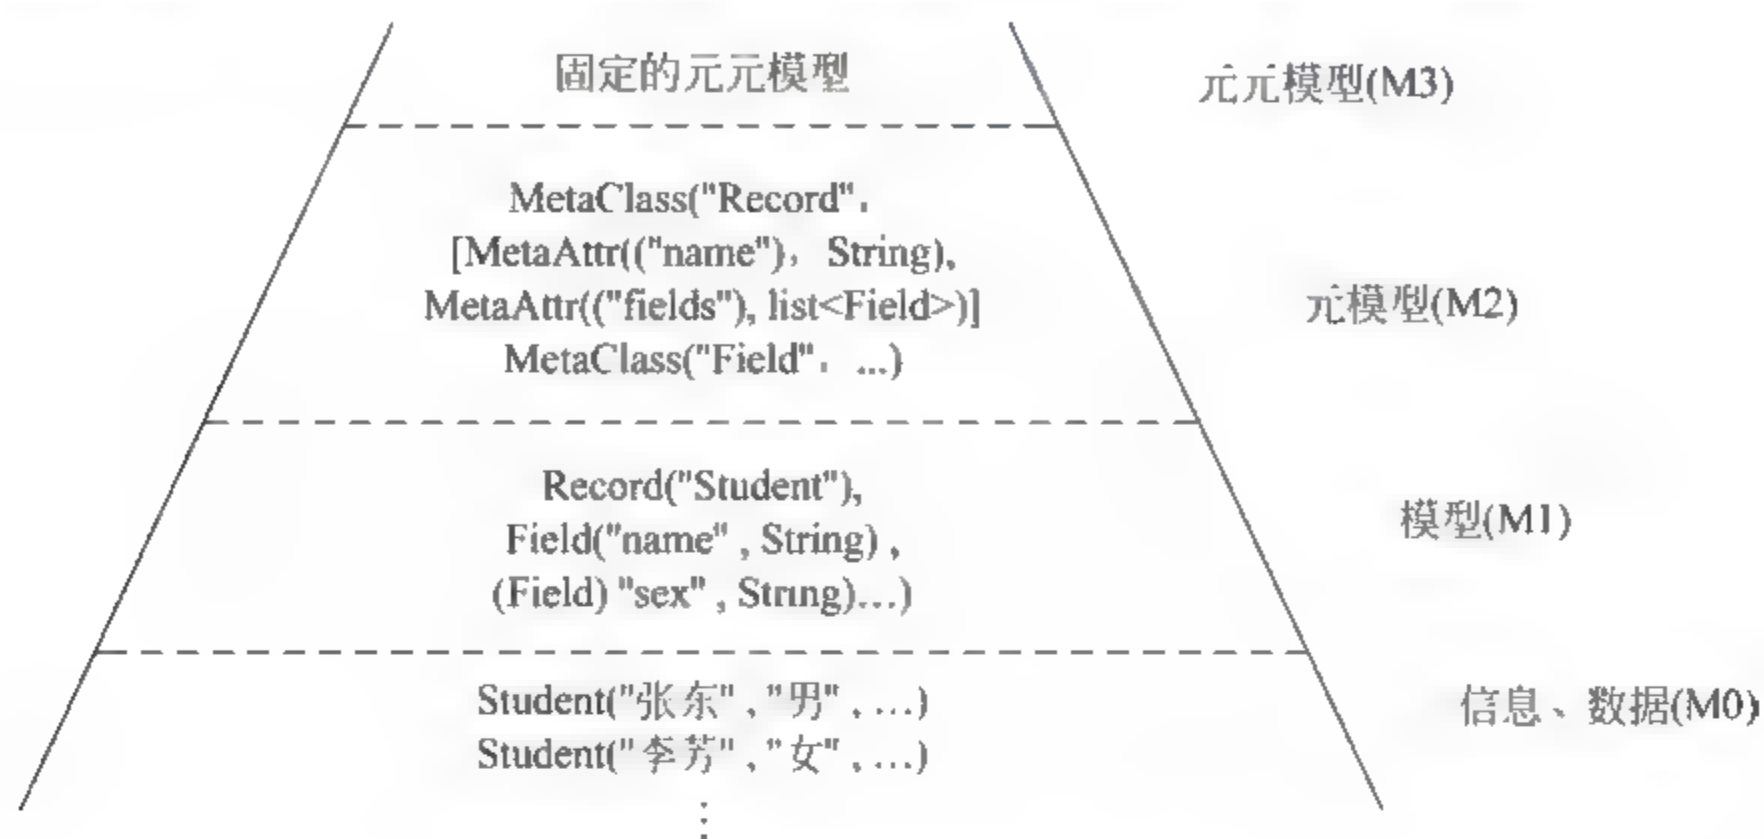


图 1.8 元数据层次结构的实例

其中：

- (1) 数据层是学生记录(Record)的实例,即具体的某个学生。
- (2) 模型层描述学生这个记录类型的内容,它有一个名字(Student)和两个字段(Field),每个字段都有一个名称和类型,例如第一个字段的名称是 name,字段类型是 String。
- (3) 元模型层对 Record 这一类型进行定义,在这一层 Record 是元类 MetaClass 的一个实例,一个 Record 拥有两个元属性 MetaAttribute,第一个 name 定义其名字,是 String 类型;第二个 fields 定义它包含的字段集,字段集的成员是 Field 类型。类似地,元类 Field 应该也包含两个元属性,即名字(Name)和类型(Type)。
- (4) 元元模型层的结构基本固定,它将所有概念抽象为以下组件:元类 meta-Class、元属性 meta Attribute 和元关联 meta-Association,并定义了元类之间的关系,主要包括包含(Contains)、继承(Generalizes)、类型引用(IsOfType)和依赖(DependsOn)。

理论上还可以再向上抽象,但由于元元模型层是自描述的,所以四层足够了。至于为什么要抽象出上面两层,则是为了支持各种不同的模型和元模型。

综上所述,OMG 的上述规范和元数据四层结构的对应关系如表 1.2 所示。

表 1.2 OMG 规范和元数据四层结构的对应关系

元数据层次	MOF 术语	示 例
M3	元元模型	MOF 模型
M2	元模型、元元数据	UML 元模型、CWM 元模型
M1	模型、元数据	UML 模型、CWM 模型
M0	对象、数据	数据仓库数据

#### 4. 组成

CWM 完整地描述了数据仓库元数据交换的语法、语义以及用于异构平台之间的元数据交换机制,它由三部分组成。

### 1) CWM 元模型

CWM 元模型描述数据仓库的组成元素,用户可以按照这些元模型开发相应的组件,例如 ETL、OLAP 和数据挖掘等。为了降低复杂度并重用,CWM 元模型采用分层的方式组织所包含的包,如图 1.9 所示。

管理包 分析包 资源包 基础包	数据仓库处理		数据仓库运行		
	转换		OLAP	数据挖掘	信息可视化
	面向对象	关系	记录	多维	
	业务信息	数据类型	表达式	关键字和索引	类型映射
	XML				

图 1.9 CWM 元模型的包结构

图 1.9 中 CWM 元模型主要包括四层:基础包(Foundation)、资源包(Resource)、分析包(Analysis)和管理包(Management)。

基础包主要定义为 CWM 其他包所共享的一些基本概念和结构,包含的子包如下:

- (1) 业务信息(business information):定义面向业务的通用信息,例如负责人信息等。
- (2) 数据类型(data types):定义其他包用以创建所需的数据类型的元模型组件。
- (3) 表达式(expressions):定义 CWM 其他包定义表达式所需的元模型组件。
- (4) 关键字和索引(keys and indexes):定义描述关键字和索引的共享元模型。
- (5) 软件部署(software deployment):描述一个软件在数据仓库中如何被使用的元模型。
- (6) 类型映射(type mapping):支持不同系统之间数据类型映射的元模型。

资源包主要定义一些描述常用的数据源/目标的元模型,包含的子包如下:

- (1) 关系(relational):描述通过关系型接口访问的数据库的数据模型和元模型,例如 RDBMS、ODBC 和 JDBC 等。
- (2) 记录(record):描述记录的基本概念和结构的元模型,这里记录的概念很广泛,它可以描述任何结构化的信息,例如数据库的一条记录、文档等。
- (3) 多维(multidimensional):描述多维数据库的元模型。
- (4) XML:描述用 XML 表示的数据源和数据目标。

分析包主要定义一些描述数据仓库工具的元模型,包含的子包如下:

- (1) 转换(transformation):定义数据仓库中抽取转换规则的元模型,包含对各种类型数据源之间转换规则的描述。
- (2) OLAP:对 OLAP 工具和应用进行描述,并定义其到实际系统的映射。
- (3) 数据挖掘(data mining):对数据挖掘工具和应用进行描述。
- (4) 信息可视化(information visualization):定义问题域中有关信息发布或信息可视化的元模型。

(5) 业务命名(business nomenclature):对业务数据进行描述,例如业务术语及其适用范围等。

管理包主要定义一些描述数据仓库运行和调度信息的元模型,包含的子包如下:

- (1) 数据仓库处理(warehouse process):描述数据仓库中抽取转换规则的执行过程,即各转换规则的触发条件。



(2) 数据仓库运行(warehouse operation): 描述数据仓库日常运行情况的元模型。

## 2) CWM DTD 和 CWM XML

CWM DTD 和 CWM XML 是对应于 CWM 中所有包的 DTD 和 XML, 它们都遵循 XMI 规范。定义 CWM DTD 和 CWM XML 的主要目的是为了基于 XML 进行元数据交换。因为 XML 在各个领域的应用越来越广泛, CWM 提供元模型到 XML 的转换, 无疑增加了其自身的通用性, 各种分析工具和元数据库可以利用这些模板为其元模型生成 DTD 和 XML 文档, 这样就可以和其他工具之间进行元数据交换。

## 3) CWM IDL

CWM IDL 为上述所有的包定义了符合 MOF 1.3 的 IDL 接口, 这样就可以利用 CORBA 进行元数据交换。用户可以创建一些具有分析功能的软件包, 例如数据挖掘组件等, 提供 CWM 中规定的 IDL 接口, 就可以被其他支持 CWM 的工具和数据仓库调用, 这大大增强了 CWM 的灵活性和适用性。

## 5. 特点

通过对 CWM 组成的介绍, 可以看出 CWM 具有以下特点:

(1) 对所有的数据仓库功能元数据定义了详细的元模型和交换方式, 包括技术元数据(例如 Software Deployment、Transformation、Warehouse Process 等)和业务元数据(例如 OLAP、Business Information 等)。

(2) 定义了一个通用且强大的 Transformation 包, 可以表示任何数据源和数据目标之间的转换规则。此外, 还为多种常用的数据源/目标(例如 Relational、Record、Multidimensional、XML 等)和工具相关的数据源(例如 IMS、DMSII、COBOL Data、Essbase 和 Express 等)定义了元模型和交换方式。

(3) 对所有的数据仓库运行元素定义了元模型和交换方式, 包括调度、状态报告和历史记录等。

(4) 对所有的分析型数据以及主要的分析型数据模型定义了元模型和交换方式, 例如多维模型。

(5) 对操作型数据以及主要的操作型数据模型定义了元模型, 例如关系型和面向对象型。

## 6. 目标和原则

CWM 的主要设计目标和原则如下:

(1) 对 UML 中概念的重用: UML 1.3 是整个 CWM 的设计基础, CWM 在任何可能的地方对 UML 中的概念进行重用, 所有的 CWM 对象类型都直接或间接地继承于 UML, 因此也继承了其属性和方法。这样可以节省很多重复工作, 并且使 CWM 更容易理解, 所有熟悉 UML 的用户都可以有一个比较高的起点。

(2) 模块化: CWM 元模型被分成许多包, 以便它们分别实现并减少复杂度。

(3) 通用化: CWM 元模型独立于任何具体的数据仓库工具。同时, 它尽量多地包含了基于特定工具实现的有代表性且通用的数据仓库特点。换言之, 只有那些多种工具共享的信息才会被 CWM 元模型所包含。

## 7. 应用

CWM 主要面向以下几类用户:

(1) 数据仓库平台和工具提供商: CWM 提供了一个组件可插卸的通用系统框架, 因为



这是一种全球通用的元数据交换协议,所以可以很方便地在各种异构平台上发布自己的产品。

(2) 数据仓库服务提供者:可重用、可编辑、可扩展的 CWM 元数据大大提高了工作效率。因为 CWM 与产品无关,所以可以避免大量的重复工作。

(3) 数据仓库管理员:数据仓库管理员有时需要对现有工具进行整合,而 CWM XML 无疑提供了一种最方便的整合方式。另外,管理员经常需要对资源进行增减、分区或者重新分配,CWM 提供了这方面的元数据以帮助完成这些工作,并对改变造成的影响做出评估。

(4) 终端用户:CWM 为查询和展示工具定义了元模型,更方便、快捷地为其展示所需的信息。

(5) 信息技术管理员:CWM 为系统管理和报表工具定义了元模型,使得用户能够更轻松地对系统和信息进行管理。

#### 1.4.4 UML、MOF 和 XMI 与 CWM 的关系

##### 1. UML 与 CWM

UML 是一种面向对象的建模语言,由面向对象的三种主流建模语言 Booch、OMT 和 OOSE 综合而得,后来被 OMG 定义为面向对象建模的标准语言。目前有很多图形工具支持它,并已得到广泛应用。

UML 定义了多种模型元素,支持面向对象系统的静态建模和行为建模。UML 静态模型包含对类及其属性、操作、接口的定义和类之间关联(例如继承、依赖和包含等)的定义。对系统行为语义的建模可以用序列图和协作图完成。CWM 规范主要使用 UML 的静态图。

UML 语言由一个以 UML 表示的元模型(或语义模型)定义,这种递归定义使得整个 UML 可以基于非常少的(三个)未定义元素。此外,MOF 定义了 UML 的元元模型以表示一个递归的 UML 元模型的语义。

CWM 元模型直接从 UML 元模型继承而来,换言之 CWM 中的类都直接或间接地继承了 UML 中类的语法和语义。例如 CWM Relational 包中的关系模型定义了一个 Table 类,表示任何关系数据库的表,这个类继承于 UML 中的 Class 类。类似地,Column 类继承于 Attribute 类,这就建立了 Table 和 Column 之间的语义关系,即 Table 是一些 Column 的集合,这些 Column 具有一些共同的属性,但各自的属性值不同。这等同于 UML 中类和属性的关系,把 Table 和 Column 分别作为类和属性的子类就内在地确立了这种等同关系。CWM 这种直接从 UML 核心元模型中派生出数据仓库领域元模型的好处有很多,例如:

(1) CWM 元模型成为 UML 核心元模型的扩展,即可以直接使用 UML 作为构建数据仓库领域元模型和模型(元模型的实例)的语言。

(2) CWM 可以直接使用 UML 图形标记表示数据仓库元模型。

(3) CWM 可以直接使用 UML 元模型中已经定义的语法和语义,无需重新定义,这通常指对抽象层次比较高的元类及其关联等概念的重用。例如 CWM Relational 包中的元类 Table 和 Column 之间的关系继承了 UML 中的元类 Classifier 和 Feature 之间的关系,在



CWM 的 Relational 元模型中就无需明确定义 Table 和 Column 之间的关联。

(4) CWM 元模型可以直接使用 UML 元模型中定义的数据类型。UML 元模型用元类 DataType 定义了数据类型的概念,在 CWM 中可以通过为 DataType 定义 M2 层描述的方式对其扩展,添加一些标准的数据类型,如 SQL 或 CORBA 中的标准类型等。

(5) CWM 使用 UML 元模型作为描述面向对象型数据源的元模型。

(6) CWM 可以使用 UML 规范中定义的 OCL(Object Constraint Language,对象约束语言)表示对 CWM 元模型的约束条件。

## 2. MOF 与 CWM

MOF 是 OMG 用来定义元数据并将其表示为 CORBA 对象的一种技术,它支持任何能用对象建模技术表示的元数据,这些元数据可以按照用户需求在任意层次、程度描述系统的任何信息。

模型作为一种对现实世界的描述方法也是元数据。模型的概念是高度可变的,它依赖于观察的角度。例如对于那些关心整个系统的人而言,模型应该包括系统所有的元数据。在 MOF 中,模型可以是任意具有抽象语法和语义的元数据的集合。元数据本身就是一种数据,因此它还可以被其他元数据描述。在 MOF 中,包含这种元数据的模型称为元模型。MOF 元模型定义了用 MOF 格式描述模型中元数据的抽象语法,因为一个系统中一般都会有很多类型的元数据,相应地就会有多种元模型。为了集成这些元模型,MOF 定义了一套通用的元模型构造语法,这种语法称为 MOF 模型,它是描述元模型的模型。实际上,它处于 M3 层,应该是元元模型,这里简称为 MOF 模型。

MOF 规范由三部分组成:MOF 模型规范、MOF IDL 映射和 MOF 接口。

MOF 模型是 MOF 内部定义的元元模型,可以看做是定义 MOF 元模型的抽象语言,这和 UML 元模型定义 UML 模型类似,只不过前者是为了元数据建模,后者是为了对象建模。实际上,基于 MOF 的模型就是用 UML 标识表示的。MOF 主要提供四种组件构造 MOF 元模型,即类(class)、关联(association)、包(package)和数据类型(data type)。这些概念和 UML 中的类似,只是进行了一些简化,具体如下:

(1) 处于定义和实现层的类都可以拥有属性和方法。在 MOF 元模型中,属性表示元数据;方法提供对特定元模型中元数据的操作。属性和方法的参数可以定义为有序。

(2) 关联支持对类的实例的二元连接。每个关联都有两个端点,并可以对其排序性和唯一性等方面进行限制。如果一个类是一个关联的端点,那么它就可以包含通过这个关联到对方类的实例的引用。

(3) 包是相关的类和关联的集合。包之间可以引用、继承和嵌套。

(4) 数据类型使属性和参数可以使用非对象的类型。在 MOF 中,它们必须是能够用 CORBA IDL 表示的数据类型或接口类型。

MOF IDL 映射是一套将 MOF 元模型映射到 CORBA IDL 的标准模板。MOF 元素(M2 层)到 CORBA 对象(M1 层)的映射关系如下:类映射为元数据对象的 IDL 接口和元数据类代理,IDL 接口支持原类中定义的属性、操作和引用,而类代理提供对元数据对象的代理操作。MOF 关联映射为元数据关联代理的接口,这个关联代理支持对关联的查询和更新操作。MOF 包映射为一个接口和元数据包代理,这一包代理实际上是包含原包中类和关联的代理的容器。



MOF 接口是表示 MOF 元模型的 CORBA 对象的接口,一般使用现有工具访问 MOF 模型库,其建模开发人员无需了解,只有那些开发基于 MOF 工具的程序员才需要了解。

OMG 已经采用 MOF 作为定义元模型的标准,CWM 元模型就遵循这一标准。这样,CWM 就可以使用 OMG 其他基于 MOF 的标准,尤其是可以用 XMI 交换 CWM 模型表示的数据仓库元数据,并用 IDL 和其他程序语言访问这些元数据。

### 3. XMI 与 CWM

XMI 的主要作用是用流的方式进行模型交换,因为 OMG 采用 MOF 表示元数据,XMI 的重点自然就是 MOF 元数据(即遵循 MOF 元模型的元数据)的交换。XMI 支持任何能用 MOF 规范表示的元数据的交换,它不仅可以对整个模型或部分模型组成的元数据进行编码,还可以对特定工具扩展的元数据编码。

XMI 可以看作是一种独立于中间件的通用的元数据交换格式,任何能够编写和解析 XML 数据流的元数据库或工具之间都可以进行元数据交换,它们无需实现 MOF 定义的 CORBA 接口,甚至根本不用支持 CORBA。XMI 还为非 MOF 的元数据库提供了一种交换方式,只要它能够将自身的元模型映射为 XMI 文档即可。

XMI 基于 W3C 的 XML,实际上就是一对并行的映射,一个在 MOF 元模型和 XML DTD 之间,另一个在 MOF 元数据和 XML 文档之间。

XMI 主要由以下两部分组成:

(1) XML 文档生成规则:定义了将元数据编码为 XML 格式文档的规则,利用这一规则还可以将 XMI 文档解码得到元数据。

(2) XML DTD 生成规则:定义了为编码后的元数据生成 XML DTD 的规则,DTD 是 XML 文档的语法说明,一般的 XML 工具都可以用它来解析和验证 XMI 文档。

CWM 用 XMI 作为交换机制,这样数据仓库元数据和 CWM 元模型本身都可以充分利用 XMI 的灵活性和强大性。CWM 元模型通过 XMI DTD 生成规则产生一个标准的 DTD,而数据仓库元数据则可以通过 XMI 文档生成规则编码为一个 XML 文档。这大大增加了 CWM 的适用性,任何能够编写和解析 XML 数据流的元数据库或工具之间只需将自身的元数据转换为 CWM 模型的形式就可以利用 XMI 实现元数据交换,即它们所描述的数据交换。

## 1.5 数据粒度

数据仓库保存了大量的历史数据,为了保证数据的存储效率和组织清晰,数据仓库的数据以不同粒度存储。

数据仓库存在不同的综合级别,一般称之为“粒度”。粒度越大,表示细节程度越低,综合程度越高。四种粒度级别分别是早期细节级、当前细节级、轻度综合级和高度综合级,分别反映不同的需求。由此可知,数据仓库的数据生存周期,即源数据经过综合后首先进入当前细节级,并根据具体需要进一步综合,从而进入轻度综合级乃至高度综合级,老化的数据将进入早期细节级。数据仓库的核心是在系统中保留最有可能被用户使用的数据。



## 1.6 数据模型

数据模型是对现实世界的一种抽象,根据抽象程度的不同,形成了不同抽象层次上的数据模型。类似于关系型数据库的数据模型,数据仓库的数据模型也分为三个层次,分别是:

### 1. 概念模型

概念模型是客观世界到计算机系统的一个中间层次,最常用的表示方法是 E-R(Entity-Relationship,实体-关系)图。目前,数据仓库一般是建立在数据库的基础之上,所以其概念模型与一般关系型数据库的概念模型一致。

### 2. 逻辑模型

逻辑模型是数据的逻辑结构,如多维模型、关系模型和层次模型等。数据仓库的逻辑模型描述了数据仓库的主题的逻辑实现,即每个主题对应的模式定义。

### 3. 物理模型

物理模型是逻辑模型的具体实现,如物理存取方式、数据存储结构、数据存放位置以及存储分配等。在设计数据仓库的物理模型时,需要考虑一些提高性能的技术,如表分区、建立索引等。

目前,对数据仓库数据模型的讨论大多集中在逻辑模型,其中最常用的是多维模型。在多维模型中,涉及以下一些基本概念,即:

维是指人们观察数据的特定角度。例如,企业常常关心不同销售数据随时间变化的情况,所以时间就是一个维度。

维的层次是指人们观察数据的某个特定角度还可以存在细节程度不同的多个描述,即维的层次。一个维度往往有多个层次。例如描述日期维度时,可以有年、季度、月和日等不同层次,则年、季度、月和日就是时间维度的层次。

维成员是指维的一个取值。如果一个维是多层次的,则该维度的成员就是在不同层次上取值的组合。例如时间维有年、月和日三个层次,则分别在三个层次上各取一个值组合起来就得到时间维的一个成员,即“某年某月某日”。

度量描述了要分析的数值,例如销售额等。

粒度是指数据仓库所保存数据的细化或综合程度的级别。细化程度越高,粒度越小;反之,细化程度越低,粒度越大。

## 1.7 ETL

原来业务系统的数据经过提取、转换并加载到数据仓库中心存储库的过程称为 ETL (Extract, Transform and Load)过程,制定这一过程的策略称之为 ETL 策略,而完成 ETL 过程的工具则是 ETL 工具。相对于数据仓库的表而言,业务系统数据库中的表称为源表,业务系统数据库称为源数据库,数据仓库中所有的数据都来自于业务系统数据库。在构建数据仓库过程中,ETL 的实施是一项烦琐、冗长而艰巨的任务,因为它关系到数据仓库的数据质量问题,如果导入的数据漏洞百出,对决策者而言无疑是噩耗。

### 1.7.1 主要流程

随着应用和系统环境的不同,数据的抽取、转换和加载具有不同的特点。一般地,ETL 主要过程如图 1.10 所示。




图 1.10 ETL 主要过程

(1) 预处理是正式开始作业之前的准备工作,包括清空工作区、检查过渡/准备区。如果需要直接访问操作型数据源时,要检查远程数据库服务器状态,并核对目标区数据加载状态,以核算出加载作业的参数,如加载数据的时间间隔和范围(是 24 小时的数据,还是前 3 天的数据)。

(2) 启动数据加载的批作业。

(3) 因为维表有事实表所参照的主键,所以需要先完成对维表的加载,生成维表主键,并作为以后加载事实表所需的外键。在加载维表时,有时需要处理好缓慢变化的维,并可能涉及版本号的处理问题。

(4) 加载事实表。这中间也涉及键查找的问题,即从有关维表中找到相应的主键,并以此作为事实表的外键。

(5) 事实表加载完成后,再对实体化立方体进行刷新,以保障实体化立方体与其基础数据同步。

(6) 设计具有完善的出错处理机制和作业控制日志系统,以监测和协调整个加载过程。

具体的 ETL 处理流程如图 1.11 所示。

### 1.7.2 数据抽取

数据抽取是 ETL 的首要任务,解决的主要问题是确定需要抽取的数据,并采用适当的抽取方式。

源数据进入数据仓库是通过数据抽取完成的,从一个或多个源数据库中通过记录选取进行数据复制的过程。抽取过程是将记录写入 ODS 或者临时区(staging area)以备进一步处理。

数据抽取的主要功能如下:

(1) 数据提取:主要是确定要导入数据仓库中的数据。

(2) 数据清洁:检查数据源中存在矛盾的数据,按照用户确认的清洁规则对数据进行



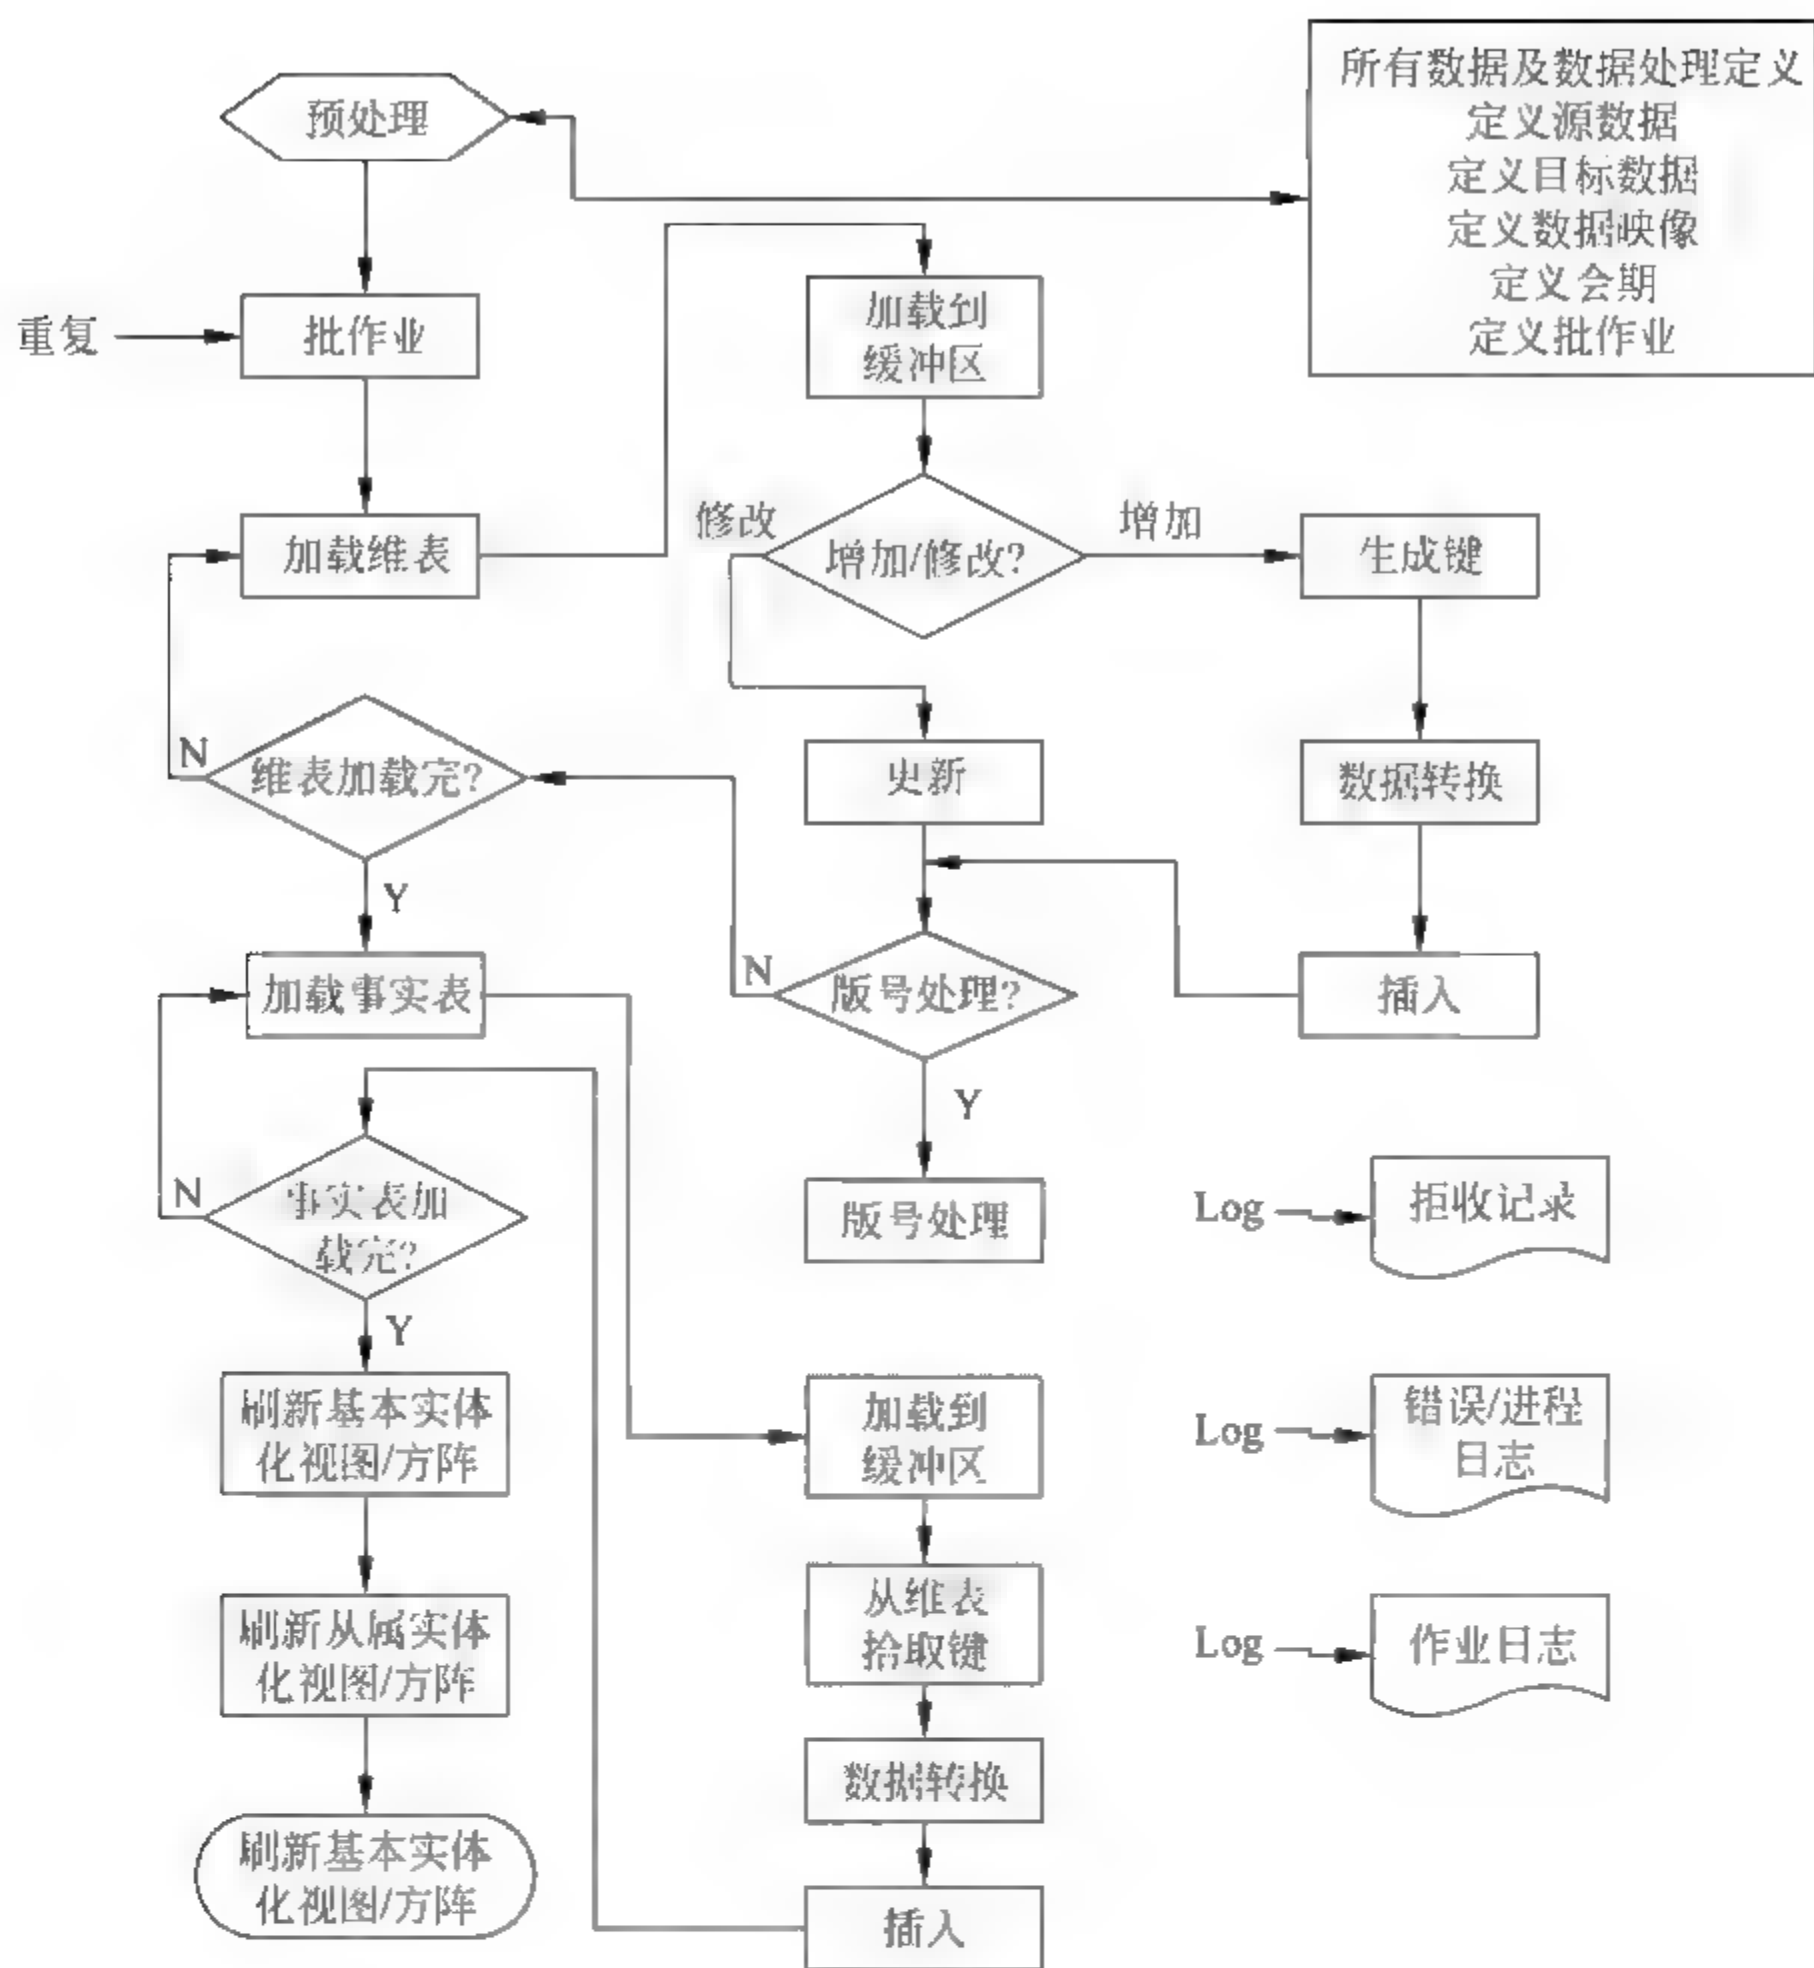


图 1.11 ETL 处理流程

修改。

(3) 数据转换：数据转换主要是将数据源的数据转换成数据仓库要求的格式，其中包括数据格式的转换，例如将数据源中的日期字段转换成数据仓库要求的字符形式；数据内容的转换主要是将同一含义的字段用统一的形式表达；数据模式的转换，由于数据仓库系统和业务系统面向的数据操作不同，所以在数据模式上也存在不同，例如电信业务的出账表的主键包括用户标识、费用项，但是数据仓库用户主题中用户账务信息采用用户标识作主键，将不同费用项的费用作为字段，这样就需要在数据抽取时进行不同数据模式间的转换。

(4) 生成衍生数据: 由于数据仓库保存了大量的历史数据, 同时要保证查询的效率, 需要对用户经常进行的查询进行预处理操作, 以提高查询效率, 生成衍生数据。衍生数据既包括某些数值数据的运算, 如平均值、汇总等, 也包括某些分类字段的生成, 例如对用户费用的分档信息等。

数据抽取的重要组成部分是变化数据捕获(Change Data Capture, CDC)。实现 CDC 的方法包括时间戳、读取 RDBMS 系统的日志文件、使用源系统中的触发器或者自行开发

CDC 程序检查日志文件等。使用时间戳是最简单也是相当普遍的方法,前提是所有的源表都有时间戳。例如超市的业务系统数据库中几乎每个表都有“插入记录日期”和“更新记录日期”两个字段,这是规范建库的一个基本标准。

多数情况下,数据源系统与数据仓库并不处于同一个数据服务器,它们往往是独立的,并处于远程系统中。数据抽取往往是以远程、分布式的方式进行,并涉及各种各样的方法和手段,主要包括:

- (1) 应用 SQL Plus 提取到文本文件;
- (2) 应用 OCI 或 Pro C 程序,或者 Oracle UTIL FILE 提取到文本文件;
- (3) 应用 Oracle Export Utility 实用程序提取到 Oracle Export Files 文件;
- (4) 远程数据复制;
- (5) 信息流。

来自操作型数据源的数据如果含有不清洁的成分和不规范的格式,将对数据仓库的构建和维护,特别是对 OLAP 造成很多问题和麻烦。因此,必须在 ETL 中加以解决,通常包括以下的处理方法:

- 设计拼写检查、分类并与标准值对照检查
- 处理名字和地址
- 为名字和地址建立辅助表或联机字典,据此进行检查和修正
- 数据转换函数以及子程序库

保障数据清洁的原则是优先对数据清洁流程进行分析和系统化设计,针对数据的主要问题和特征,设计一系列数据对照表和数据清洁程序库的有效组合,以便应对不断变化的、形形色色的数据清洁问题。

通常数据清洁处理方法如下:

(1) 预处理:对于新的数据加载文件(特别是新的文件和数据集)需要进行预先诊断和检测,不能贸然加载。有时需要临时编写判断小程序,称作“小狗”,它会用鼻子闻一闻这个庞然大物(不知底细的文件),以进行检查。

(2) 标准化处理:应用数据仓库内部的标准字典,对地名、人名、公司名、产品名、品类名等进行标准化处理。

(3) 查重:应用各种数据查询手段,避免引入重复数据。

(4) 出错处理和修正:将出错的记录和数据写入到日志文件,留待进一步处理。

数据仓库中必须存放“优质数据”,即符合一致性的、大家公认或经过验证是有价值的,并符合元数据定义的。通过数据清洁能够检测出违反规则的数据,这些数据要么抛弃,要么将其转换成“清洁”数据,使其符合规则,然后再装载到数据仓库中。

### 1.7.3 数据转换

数据转换是将抽取出的数据进行过滤、合并、解码和翻译等,为数据仓库创建有效数据的过程。一旦数据抽取完成,则需要设计并确定转换规则应用于已抽取的数据。数据转换需要理解业务侧重点(business focus)、信息需求(informational needs)和目前可用的源数据。



常用的转换规则包括：

(1) 字段级的转换,主要是指数据类型转换,增加“上下文”数据,如时间戳;将数值型的地域编码替换成地域名称,如解码(decoding)等。

(2) 清洁和净化,主要是保留字段具有特定值或特定范围的记录;引用完整性检查;去除重复记录等。

(3) 多数据源整合,主要是字段映射(mapping);代码变换(transposing)即将不同数据源中的数据值标准化为数据仓库数据值。例如将源系统非英文编码转换为数据仓库英文编码;将源系统信息编码转换为数据仓库信息编码等;合并(merging)即将两个或更多源系统记录合并为一个输出或“目标”记录;派生(derivation)即根据源数据,利用数学公式产生数据仓库需要的数据。例如,由身份证号码计算出出生日期、性别和年龄等。

(4) 聚合(aggregation)和汇总(summarization)

虽然,数据转换较为烦琐,但却是 ETL 步骤中最简单的。许多 ETL 工具都提供了很强大的转换功能,例如 DTS 中有复制字段转换、小写字符串转换、大写字符串转换、中间字符串转换、剪裁字符串转换、日期时间字符串转换、读取文件转换、写入文件转换和 ActiveX 脚本转换等,其中最常用的是 ActiveX 脚本转换,因为它允许自行利用 VBScript 或 JScript 将原始字段中的数据转换至目标字段中的数据。事实上,如果上述的各种转换类型都无法满足需求时,则 ActiveX 脚本转换将是最终的选择。

#### 1.7.4 数据加载

数据加载是将转换/清洁后的数据装载到数据仓库,实现数据加载可选用的实用程序和工具很多,例如最基本的 Import、SQL Loader 和 SQL 语言等。为了提高程序和过程的复用性,编写和设计数据转换的函数库/子程序库是十分必要的。

数据加载包括维表和事实表的加载,两者具有不同的加载策略。

##### 1. 维表加载策略

从本质上看,有三种维表加载策略。每种策略按不同的方式处理维表中的变化以及更新维表数据或捕获属性的变化历史。这三种加载策略统称为慢速变化维表策略(Slowly Changing Dimension,SCD)。在这三种策略中,所有输入数据都与现存的数据进行比较,如果在自然键上没有发现匹配的记录,那么输入的记录就被插入维表。自然键由维表中的一些列(数据项)组成,唯一能确定维表中一条记录的代理键不包括在这些列中。

慢速变化维表类型 1(SCD 1):在 SCD 1 策略中不需要保存历史记录。如果一条输入记录已经在目标维表中(根据自然键值进行判断),则可根据输入记录的数据对该记录进行更新或刷新。

慢速变化维表类型 2(SCD 2):有时记录中有一些重要值(即维表中一个或多个列组成的自然键值)需要保留。在 SCD 2 策略中,当相关事实发生时,就可保存一条维表记录。因此,如果一条输入记录中的某个字段或列值属于“重要值”,并且它与目标表中相应的列值不同,则现存的记录就已经“过期”了,则需要根据输入的记录,在维表中插入一条新记录并指派一个新的代理键值。如果输入记录中没有重要值与目标表中相应的列有所差别,则对现存记录进行更新,而不是使它过期。



慢速变化维表类型 3(SCD 3): SCD 3 与 SCD 2 非常相似,用于跟踪重要值的变化,然而这种策略不是为每个变化增加一条不同的记录,而是在现存的记录上使用不同的列来保存当前值和任意的前  $n$  个值。当探查到一个重要值发生变化时,该字段所有以前的列需要向下一列移动,第  $n$  个以前的值将被丢弃。但是这种策略并不被很多数据仓库专家看好,所以不建议使用,因为这将加大 ETL 的难度。

所有的维表加载都遵循上述三种策略,但有两个维表例外,即静态维表和完全由新数据替换的维表。静态维表不会变化,如果它发生变化,则发生的唯一变化是在其中添加一条新记录,时间维表就是一个静态维表;完全由新数据替换的维表通常是小的代码列表,它们不需要代理键或变化历史。但需要注意的是表中的任何重要值的丢失都是不可承受的。

## 2. 事实表加载策略

事实表的加载是必需的也是非常重要的,它是后续数据分析的基础。事实表的加载就是持续不断地增加数据。事实表的加载不是简单的数据拷贝,必须首先将每个事实表与各自维表的代理键相结合,每个源表(与事实表关联的表)必须有足够的信息用以查找维表中的自然键,以验证事实记录的完整性。

在数据加载过程中,经常涉及主键查找的问题。主要是对某些键查找函数程序进行修改补充,原因是这些键查找程序需要异常控制(exception handing)以返回两种不同的结果(找到的键值或空值)。

在加载维表的过程中,在插入新记录或修改已有记录之前,需要通过对某些逻辑键进行比较以确定当前记录是否存在。在加载事实表的过程中,经常涉及更多的主键查找处理。我们知道,数据仓库的事实表含有许多外键,并以此与有关维表的主键关联。在进行事实表加载时,往往需要查找有关维表的主键值,并以此确定事实表的外键值。常用的方法是,通过从源数据提取的数据部分的逻辑键与数据仓库内有关维表的逻辑键进行比较和匹配,如果匹配,则取维表的主键值,并以此作为事实表的外键值加载到事实表中。例如对客户维度而言,可以通过客户的姓名、邮政编码与客户维度进行比较,如果匹配,则以客户标识符键作为事实表的外键。

逻辑上,实现 ETL 主要采用三种策略,即远程抽取(remote extraction)、推(push)和拉(pull)。其中,远程抽取是指 ETL 过程是在一个独立的远程平台上进行,这种方式受数据源现有系统或目标数据仓库的结构影响最小,几乎不影响源和目标系统的 CPU 和容量,但可能会提高成本,对网络带宽要求较高。推是指在现有系统环境中开展 ETL 过程。当现有系统具有相当充裕的容量,而且不会超出 CPU 处理限度时,经常采用这种方法。现有系统是同构的也经常采用这种方式。拉是指 ETL 过程在“仓库”端进行,现有异构系统经常采用这种方式。当“仓库”端平台具备必需的性能和容量时,将体现出一定优势。但是由于“仓库”的不断增长,可能需要制定长期的策略。



## 第2章 数据仓库设计和实现

### 2.1 数据仓库设计

数据仓库是一个面向数据分析处理的数据环境,数据仓库的数据具有四个基本特征,即面向主题的、集成的、不可更新的、随时间变化的。这些特点说明数据仓库从数据组织到数据处理与传统的数据库存在很大区别,数据仓库系统设计与数据库系统设计的不同主要表现在以下几个方面:

(1) 面向的处理类型不同。操作型数据库系统的设计是建立一个操作型数据环境,其设计方法是面向应用的。即一般是从具体应用出发进行数据库设计,然后在数据库上建立这些应用。数据仓库系统的设计则是面向分析的,往往是从最基本的主题开始,不断地扩展新的主题,完善已有的主题,最终建立一个面向主题的分析型数据环境。

(2) 面向的需求不同。面向应用的数据库系统设计具有比较明确的应用需求,这是数据库系统设计和开发的出发点和基础。在数据仓库环境下,不存在操作型环境中固定的且较明确的物流、数据处理流和信息流。数据分析处理的需求更灵活,没有固定的模式,甚至用户自己也对所要进行的分析处理不甚明了,因而在数据仓库系统设计时,很难获得对用户需求的确切了解,这就决定了不可能从用户需求出发进行数据仓库的设计。

(3) 系统设计的目标不同。设计数据库系统时,事务处理的性能(主要表现为事务处理的响应时间)是系统设计的一个主要目标;而设计数据仓库系统时,更关注的是建立一个全局一致的数据环境,作为企业决策支持系统的基础,因此数据仓库设计的一个主要目标是保证数据的四个基本特征,保证数据的全局一致性,实现对企业数据的全局管理和控制。

(4) 数据来源或系统的输入不同。操作型环境的数据输入通常来源于组织外部,设计操作型数据库即是设计如何通过与外部交互获取数据,如何将获取的数据以适当的方式进行存储,如何对数据进行联机查询、更新等操作,以及如何保证数据的安全可靠与正确有效等。而数据仓库的数据主要来源于已有系统内部,设计数据仓库即是设计如何从现有的数据源中获取完整一致的数据,如何将获取的数据进行转换、重组和综合,如何有效地提高数据分析的效率和准确性等。

综上所述,数据仓库的设计主要包括两个方面——与操作型系统接口的设计和数据库本身的设计。从某种程度上而言,“设计”并不能精确描述在启发方式下构建数据仓库时发生了什么。首先,载入一部分数据,供DSS分析员使用和查看;然后,根据最终用户的反馈,在数据仓库中修改、增加一些数据。这种反馈循环贯穿于整个数据仓库的开发过程。那种认为在构建数据仓库时,采用过去曾使用的设计方法就可以满足需求的想法是错误的。在数据仓库部分载入并且为DSS分析员使用之前,数据仓库的需求是不可能知道的。因此,设计数据仓库时不能采用与设计传统的“需求驱动”系统同样的方法。另一方面,那种认为不预测需求是好思路的想法也是错误的。实际上通常是介于两者之间。

概括地,数据仓库的设计主要包括:



- 体系结构设计；
- 数据仓库模型设计；
- 数据装载接口设计；
- 数据仓库管理；
- 元数据管理。

### 1. 体系结构设计

根据在业务和信息调研中所了解的用户业务环境和 IT 环境,设计数据仓库的整体架构,确定数据仓库的位置、网络需求、用户访问数据仓库的方式等。体系结构设计是对建立一个数据仓库系统的总体描述,从宏观和整体角度对数据仓库系统的各组成部分进行总体设计,并确定在设计过程中应遵循的总原则,保证数据仓库各个部分在开发过程中能够依据同样的基础和标准,在运行过程能够相互协调配合。后续的数据转换、应用开发、系统管理等工作将参照体系结构的设计和指导原则进行。

### 2. 数据仓库模型设计

数据仓库模型设计包括概念模型设计、逻辑模型设计和物理模型设计三部分。首先进行的是概念模型设计,以确定数据仓库的主要主题及其相互关系。概念模型设计主要完成以下工作:

(1) 界定系统边界,即进行任务和环境评估、需求收集和分析,了解用户迫切需要解决的问题及解决这些问题所需的信息,需要对现有数据库中的数据有一个完整而清晰的认识。

(2) 确定主要的主题域,即确定系统所包含的主题域,然后对每一主题域的公共码键、主题域之间的联系、充分代表主题的属性进行较明确的描述。数据仓库中的概念模型设计经常采用 E-R 模型和面向对象的分析方法。

逻辑模型设计是按照企业的业务规则和流程将各种数据有机地集成在一个完整的逻辑数据模型中。逻辑数据模型包括各个业务实体、业务实体的属性,以及业务实体之间的关系等。通过逻辑设计,可以对每个主题的逻辑实现进行定义,并将相关内容(如适当的粒度划分、合理的数据分割、增加的衍生字段、记录系统定义等)记录在数据仓库的元数据中。

物理模型设计主要解决数据的存储结构、索引策略、存储策略、存储分配优化等问题。其主要目的是提高性能,二是更好地管理存储数据。访问频率、数据容量和存储介质配置都会影响物理设计的最终结果。

### 3. 数据装载接口设计

数据装载接口即载入程序,可实现数据装载和数据综合功能。数据装载功能实现数据抽取、转换、清洗和集成;数据综合功能实现将集成的细节数据转化为不同综合层次的数据。

### 4. 数据仓库管理

数据仓库管理负责安全和权限管理。跟踪数据更新,数据质量检查,管理和更新元数据,审计和报告数据仓库的使用和状态,删除数据,复制、分割和分发数据,备份和恢复数据,存储管理。

### 5. 元数据管理

元数据为访问数据仓库提供了一个信息目录(information directory),该目录全面地描



述了数据仓库中有什么数据、如何获取以及访问这些数据,是数据仓库运行和维护的中心,数据仓库服务器利用它存储和更新数据,用户通过它了解和访问数据。元数据通常存储在专用的数据库中,该数据库可视为一个“黑盒”,外部无法知道这些工具所用到和产生的元数据是如何存储的。此外,还有一类被称为元数据知识库(metadata repository)的工具,它们独立于其他工具,为元数据提供一个集中的存储空间,如 Microsoft 的 Repository、CA 的 Repository、Ardent 的 MetaStage 和 Sybase 的 WCC 等。

### 2.1.1 设计方法

在操作型环境中,业务过程和规则比较规范且固定。设计人员能够清晰地了解应用需求和数据流程,系统设计一般采用系统开发生命周期(System Development Life Cycle, SDLC)方法。而在分析型环境中,DSS 分析员一般是企业的中上层管理人员,他们对决策分析的需求不能预先做出规范说明,只能给设计人员一个抽象、模糊的描述。这就要求设计人员在与用户不断的交流过程中,将系统需求逐步明确和完善。人们为了突出这种需求不确定的开发过程,将数据仓库的设计方法描述成数据仓库环境下的系统开发生命周期方法(Cycle Life Development System, CLDS),CLDS 与 SDLC 相反。CLDS 是典型的数据驱动,而 SDLC 是典型的需求驱动,如图 2.1 所示。

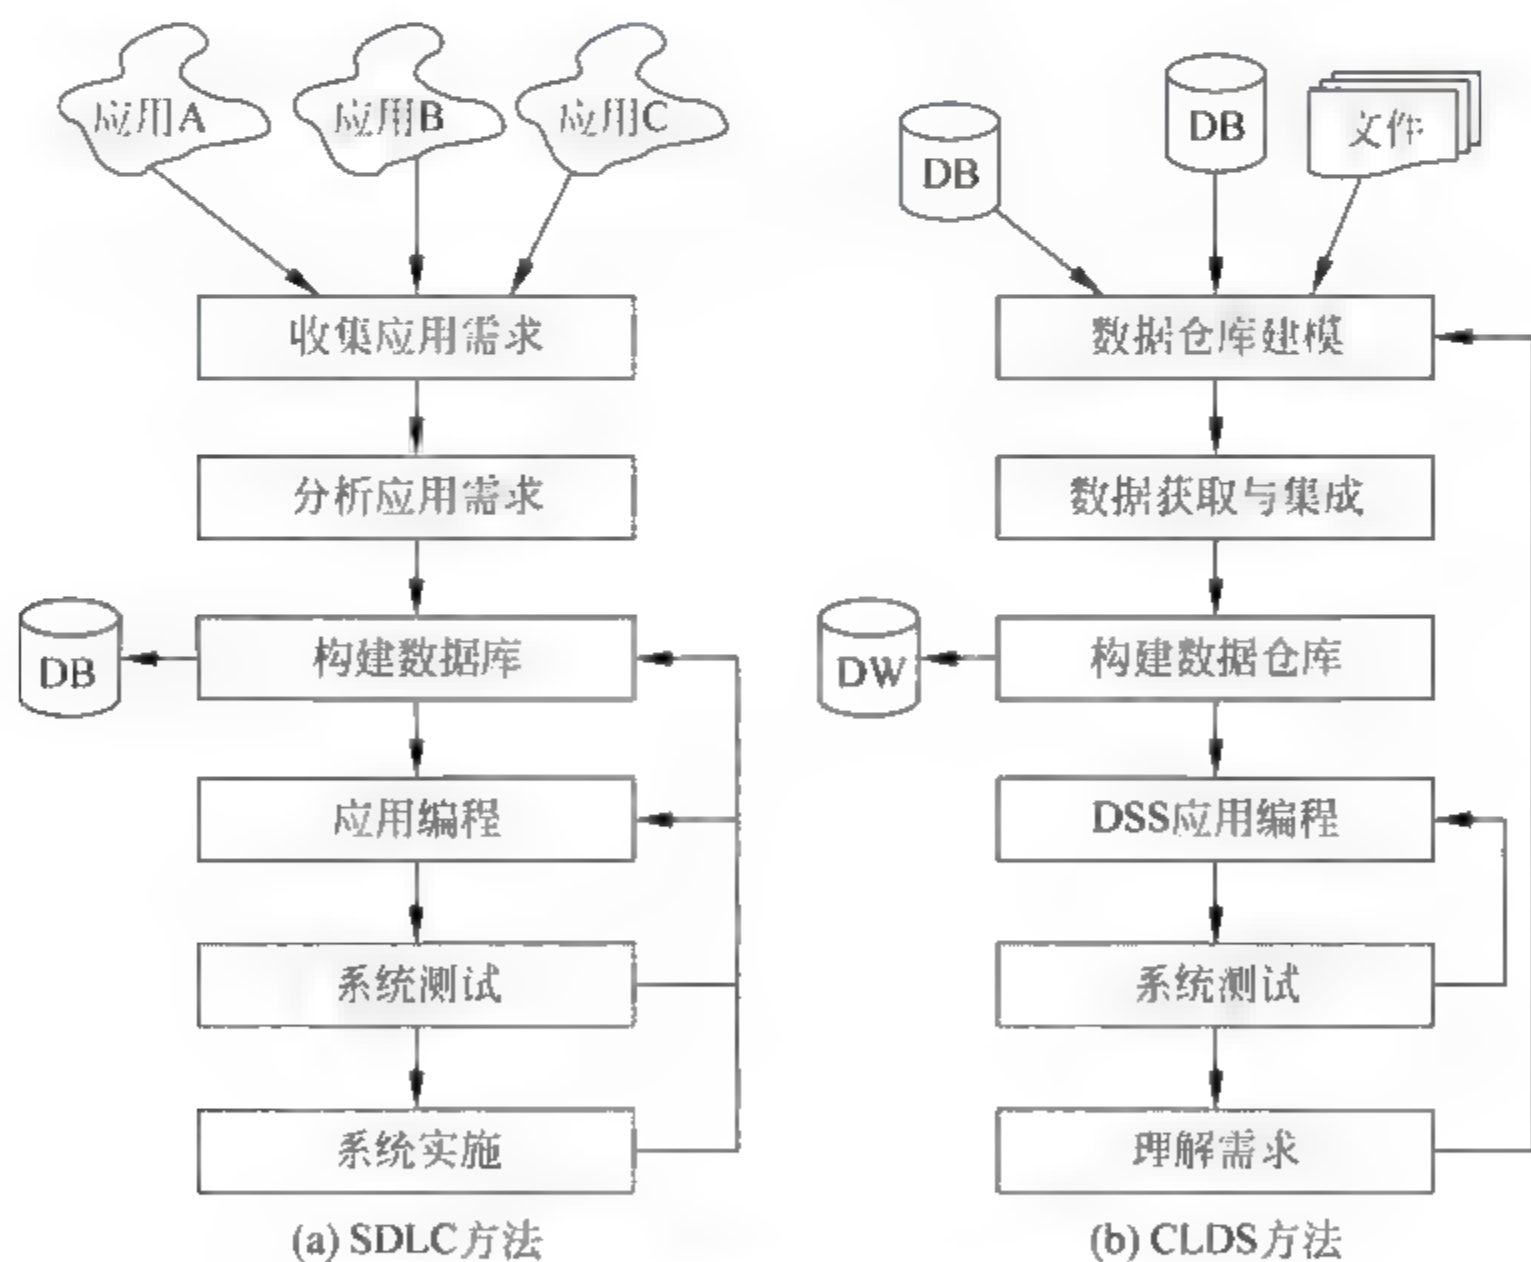


图 2.1 SDLC 方法与 CLDS 方法

数据库系统设计常用的 SDLC 方法有独立的收集需求和分析需求的阶段,SDLC 方法开始于需求,结束于代码。而数据仓库系统设计采用的 CLDS 方法没有这样的独立阶段,而是将需求分析的过程贯穿在整个设计过程中,CLDS 方法是开始于数据,结束于需求。因为联机事务处理的需求是较为固定的,如商场的库存管理、采购业务等都有一定的操作规程,



所以在—个系统开发生命周期内,系统需求在设计的前期阶段即收集需求和分析需求阶段结束后就应该确定,一旦进入 SDLC 方法的第三步构建数据库,如图 2.1(a)所示,系统需求就基本不变。而 CLDS 方法则要求在整个系统开发过程中完成对系统需求的收集、分析和理解。

数据仓库的设计方法是“数据驱动”的,其思路是利用以前所取得的工作成果进行系统设计。要充分利用现有的工作成果,唯一的办法就是能识别出当前系统设计与系统设计已完成工作的“共同性”。即在数据仓库系统设计前,需要清楚原有的数据库系统已经完成什么,以及它们对当前系统设计的影响等。应尽可能利用现有的数据、代码等,而不是什么都从头开始。从源数据出发分析数据,为新应用(分析处理)所用就是“数据驱动”的出发点。

“数据驱动”的系统设计不再面向应用,而是从已有的数据库系统出发,按照分析领域对数据与数据之间的联系重新组织数据仓库的主题。

“数据驱动”设计方法的核心是利用数据模型有效地识别现有数据库中的数据和数据仓库中主题的“数据的共同性”。

## 2.1.2 体系结构设计

数据仓库建设是一个不断循环、反馈而使系统不断扩展、完善的过程,这对系统体系结构设计提出了很高的要求,要求体系结构具有良好的可扩展性和灵活性,能适应复杂多变的业务需求,不做或少做无效、重复工作。其次,数据仓库建设的目标不是数据集成,而是通过数据集成成为业务发展提供前所未有的决策支持。因此,在数据仓库体系结构设计中应充分考虑到这一点,即结合业务应用的需求。

目前,比较成熟的数据仓库体系结构主要有两种,即企业信息工厂(Corporate Information Factory,CIF),创始人是数据仓库之父 Inmon;多维体系结构(Multidimensional Architecture,MD)又称总线架构(bus architecture),创始人是数据仓库领域中颇具实践经验的 Kimball。

### 1. 企业信息工厂

企业信息工厂主要包括集成转换层(Integrated and Transformation Layer)、操作数据存储(Operational Data Store,ODS)、企业中心数据仓库(Enterprise Data Warehouse,EDW)、数据集市(Data Mart,DM)和探索仓库(Exploration Warehouse,EW)等部件,它们有机地结合在一起,为企业提供信息服务。

集成转换层是将来自操作型源系统的数据集成并转换到数据仓库中,通常是由一组程序组成,而其他部件如数据仓库和数据集市等主要由数据组成。当业务数据来源多、业务复杂时,集成转换层建立一些临时表,为数据处理提供方便。此时,集成转换层包括程序和数  
据,也称数据准备区。通常地,中等规模以上的数据仓库系统都会建立数据准备区。

ODS 是建立在数据准备区和数据仓库之间的一个部件,以满足企业集成的、综合的操作型处理需要。例如,提供尽可能实时的、集成的报表等。一般地,ODS 用以满足企业战略决策的需要,为可选部件。

企业中心数据仓库是 CIF 的核心部件,用来保存整个企业的数据。一般地,企业中心数据仓库用以满足企业战略决策的需要,其数据来自数据准备区和 ODS。



数据集市是为了满足企业特定部门的分析需求而专门建立的数据集合。数据集市的数据来源是企业中心数据仓库。CIF的数据集市一般而言是非规范化的、定制的和汇总的。而多维体系结构的数据集市分为两种,即原子数据集市和聚集数据集市。一般而言,CIF的数据集市相当于多维体系架构中的聚集数据集市。

探索仓库或数据挖掘仓库的建立主要是为了解决大型查询,提高数据仓库的效率。当有探索或挖掘需求时,将从数据仓库导出一部分数据供其操作。

CIF的实现方式是,首先进行企业的数据整合,建立企业中心数据仓库即EDW。对于各种分析需求再建立相应的数据集市或者探索仓库,其数据来源于EDW。CIF的数据流向一般是从源系统到数据准备区到操作数据存储到企业中心数据仓库再到数据集市。当分析人员在数据仓库或数据集中获得分析结论后,将有信息的回流。这种信息回流有可能是物理数据的回流,也可能是直接改变业务部门的决策。总之,要将分析的结果应用起来。通过这种信息回流,CIF的不同部件可以不断地相互调整,最终获得平衡。

## 2. 多维体系结构

多维体系结构主要包括后台(back room)和前台(front room)两部分。后台也称为数据准备区,是多维体系结构的核心部件。它是一致性维度的产生、保存和分发的场所。同时,代理键也在后台产生。前台是多维体系结构对外的接口,包括两种主要的数据集市,一种是原子数据集市,另一种是聚集数据集市。原子数据集市保存着最低粒度的细节数据,数据以星型结构进行存储;聚集数据集市的粒度通常比原子数据集市高,与原子数据集市一样,聚集数据集市也是以星型结构进行存储。前台还包括像查询管理、活动监控等为了提高数据仓库的性能和质量的服务。多维体系结构中,首先在数据准备区建立一致性维度、建立一致性事实的计算方法;其次在一致性维度、一致性事实的基础上逐步建立数据集市。每次增加数据集市,都会在数据准备区整合一致性维度,并将整合好的一致性维度同步更新到所有的数据集市。这样,所建立的数据集市合在一起就是一个完整的数据仓库。

## 3. 比较

CIF对于建立复杂应用,如挖掘仓库、探索仓库提供了更好的支持。但这种架构的建设周期比较长,成本较高。MD中心数据仓库以多维模型保存,对于特殊的非维度型分析应用存在局限性。总体而言,这两种体系结构都是不错的选择,各有优缺点。一种比较流行的做法是联合使用,即建立CIF的数据仓库和MD的数据集市。

## 4. 实例

目前,企业采用的典型的数据仓库体系结构分为数据源、数据的存储与管理、OLAP服务器和前端工具四个层次,如图2.2所示。

(1) 数据源是数据仓库系统的基础,是整个系统的数据源泉。通常包括企业内部信息和外部信息。内部信息包括存放于RDBMS中的各种业务处理数据和各类文档数据;外部信息包括各类法律法规、市场信息和竞争对手信息等等。数据仓库可通过ODBC、JDBC和OLE DB等多种标准接口与这些系统互连。

(2) 数据的存储与管理是整个数据仓库系统的核心和关键。数据仓库的组织管理方式决定其有别于传统的数据库,同时也决定了其对外部数据的表现形式。数据仓库针对现有各业务系统的数据进行抽取、清理并有效集成,按照主题进行组织。数据仓库的组织形式按照数据覆盖范围可以分为企业级数据仓库和部门级数据仓库(通常称为数据集市)。



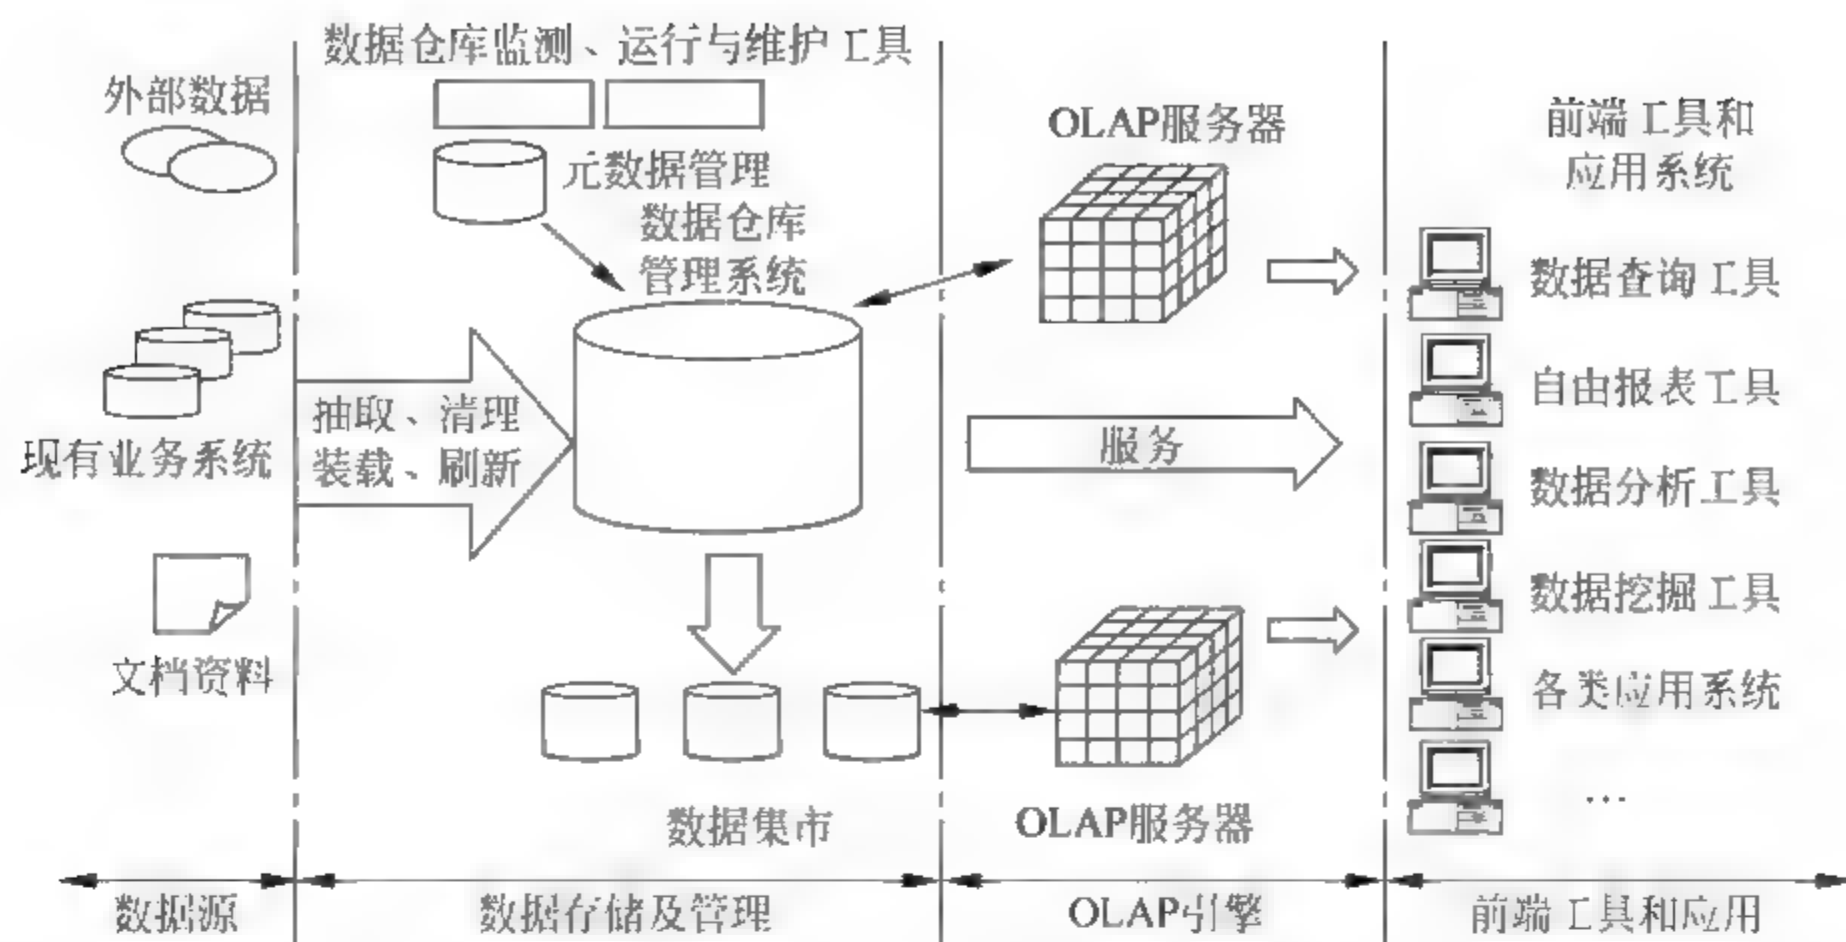


图 2.2 典型的数据仓库体系结构

(3) OLAP 服务器对分析需要的数据进行有效地集成,按照多维模型进行组织,实现多角度、多层次的分析,并预测趋势。按其具体实现可以分为 ROLAP(Relational OLAP)、MOLAP(Multi-Dimensional OLAP)和 HOLAP(Hybrid OLAP)。ROLAP 的基本数据和聚合数据均存放在 RDBMS 中; MOLAP 的基本数据和聚合数据均存放在多维数据库中; HOLAP 的基本数据存放在 RDBMS 中,聚合数据存放在多维数据库中。

(4) 前端工具主要包括各种报表工具、查询工具、数据分析工具、数据挖掘工具以及各种基于数据仓库或数据集市的应用开发工具。其中数据分析工具主要针对 OLAP 服务器,报表工具和数据挖掘工具主要针对数据仓库。

### 2.1.3 数据模型设计

数据仓库的数据模型设计是构建数据仓库的关键,正确、完备的数据模型是用户业务需求的体现,是数仓库成功与否最重要的技术因素。

由于数据仓库自身的特点,其数据模型的设计过程和传统操作型数据库数据模型的设计有很多不同,数据仓库的数据模型设计过程如图 2.3 所示。

设计的不同阶段处理的主要问题可概括如下:

- (1) 企业模型:企业模型的建立是数据仓库数据模型设计的基础,提高了模型的可扩展性。
- (2) 概念模型:完成数据仓库主题的确定,同时确定主题的范围。
- (3) 逻辑模型:确定数据仓库的数据模式,主要关注大数据量数据的存储策略以及数据仓库的处理性能。
- (4) 物理模型:使用具体的 DBMS 功能,进一步解决数据

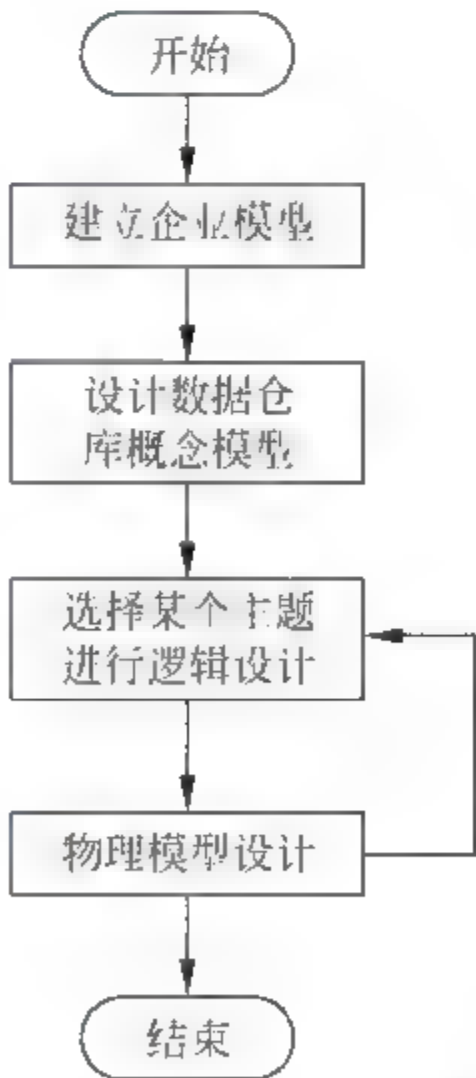


图 2.3 数据仓库的数据模型设计过程



仓库的性能。

### 1. 概念模型设计

数据仓库的概念模型描述了从客观世界到主观认识的映射。通过概念模型设计,可以确定数据仓库的主要主题及其相互关系,它主要是依据建立的企业模型确定数据仓库的各个主题,主题来源于企业模型中的实体,主题的确定需要由最终用户和数据仓库设计人员共同完成。数据仓库的主题确定后,就可以根据主题将企业模型划分成不同的部分,同时将这种划分映射到相应的数据库模型,作为下一步逻辑模型设计的基础。

概念模型设计的主要步骤是:

(1) 确定主题

(2) 划定主题边界

概念模型设计是在原有的业务数据库的基础上建立一个较为稳固的概念模型。因为数据仓库是对现有数据库系统的数据进行集成和重组而形成的数据集合,所以数据仓库的概念模型设计,首先要对现有数据库系统进行分析和理解,了解现有数据库系统中有什么、怎样组织以及如何分布等,然后再考虑应该如何建立数据仓库系统的概念模型。一方面,通过原有数据库的设计文档以及数据字典中的数据库关系模式,可以对企业现有数据库的内容有一个完整而清晰的认识;另一方面,数据仓库的概念模型是面向整个企业的,它为集成来自各个面向应用的数据库的数据提供统一的概念视图。

概念模型设计是在较高抽象层次上的设计,因此概念模型设计时不用考虑具体技术条件的限制。

### 2. 逻辑模型设计

数据仓库的逻辑模型描述了数据仓库主题的逻辑实现,相对于关系数据库而言即是描述每个主题对应的关系表中关系模式的定义。

#### 1) 模型选择

逻辑模型设计是数据仓库设计的重要步骤之一,因为它能直接反映业务部门的需求,同时对系统的物理实施具有重要的指导作用。目前,数据仓库中较常用的逻辑模型是第三范式(Third Normal Form, 3NF)和多维模型。以 Inmon 为代表的观点认为数据仓库建模应该采用基于传统的实体-关系,而以 Kimball 为代表的观点则认为数据仓库应该采用多维模型。通常在高维模型中以星型模式(star schema)最具代表性,所以有的学者把多维模型直接称作星型模式。

(1) 第三范式:实体-关系又称为第三范式,是大多数传统数据库系统的建模方法。在数据仓库的逻辑模型设计中采用第三范式,具有非常严格的数学定义。如果从其表达的含义来看,一个符合第三范式的关系必须具备以下三个条件:

① 每个属性的值唯一,不具有多义性;

② 每个非主属性必须完全依赖于整个主键,而非主键的一部分;

③ 每个非主属性不能依赖于其他关系中的属性,否则这一属性应该归到其他关系中。

第三范式的定义基本上是围绕主键与非主属性之间的关系给出的。如果只满足第一个条件,则称为第一范式;如果满足前两个条件,则称为第二范式,以此类推。因此,各级范式是向下兼容的。Inmon 提倡的第三范式建模,与操作型数据库系统的第三范式建模在侧重点上有些不同。Inmon 的数据仓库建模方法分为三层,第一层是实体关系层,即企业的业务数



据模型层,这一层和企业的操作型数据库系统建模方法是相同的;第二层是数据项集层,这一层的建模方法根据数据的产生频率及访问频率等因素与企业的操作型数据库系统的建模方法产生了不同;第三层物理层是第二层的具体实现。

(2) 多维模型:它是一种面向用户需求的、容易理解的、访问效率高的设计方法。将数据仓库的数据组织成多维模型主要是基于数据仓库支持的大部分是 OLAP 应用,而 OLAP 要求数据按照多维模型的形式组织,以支持 OLAP 的钻取、切片和旋转等操作。同时多维模型与其他的数据组织形式相比,对数据进行了大量的预汇总操作以提高数据的查询速度,这对于既要处理大量数据同时又要保证用户查询效率的数据仓库系统更为适用。另外,以多维模型的形式组织数据也符合用户的查询习惯。

多维模型中数据是按照多维形式组织的,维是用户观察数据的角度,如时间、地域等。以用户的一次通话为例,其中包括了时间、话务类型、通达地市等多个观察的维度。维是有层次的,如时间维可以按照“年、月、日”的层次划分,维度的不同层次决定了所展示数据的详细程度。根据维度的不同特性可以将维度分类,不同的分类将影响维的实现方式。

根据维度层次结构的特点,可以将维划分为:

① 均衡的层次结构。在均衡的层次结构中,每个层次的所有分支都降至同一级别,而且每个成员的逻辑父代是上一级成员。例如,移动业务中的通话区域维,可以划分为“省、地市、交换机”三个层次,如图 2.4 所示。

② 非均衡的层次结构。在非均衡的层次结构中,每个层次的分支降至不同的级别,但是同一成员的逻辑子代全部位于同一级别,如图 2.5 所示。其中,客户类型层次中的两个成员个人客户和集团客户分别降至不同的级别。

③ 不整齐的层次结构。在不整齐的层次结构中,每个层次的分支降至不同的级别,并且同一成员的逻辑子代位于不同的级别,如图 2.6 所示。其中,费用类型层次中的成员通话费的逻辑子代分别降至费用类型细分和最小费项两个不同的级别。

根据维度生成方式的不同,可以将维划分为:

① 业务实体。维来源于业务系统中的各个业务实体,并且是和主题关联的实体,例如客户、产品和销售渠道等。

② 事实属性。维也可以来自事实的属性,它们是对事实的分类,如电信业务中通话行为这一事实中的通话类型(长途、本地通话)就是通话行为的属性。一般这样的维在实体关系模型中表现为关联实体的属性。

③ 业务实体属性。这部分维是和主题关联的各个业务实体的属性,是对业务实体的分类,如客户属性中的性别、工作性质。

④ 派生维。派生维是基于事实表中其他维或度量生成的逻辑维,如电信业务中的付费方式(预付费、后付费)维是通过套餐维生成的。增加派生维,不会增加事实表中的数据量。派生维的生成依赖于用户的业务定义。

除了维的概念外,多维模型中的另一个重要概念是度量。度量是从现实系统中抽象出来描述数据的实际含义,如电信运营商的用户数、出账费用等。度量一般都是数值类型,通过使用聚集函数得到。通过度量可以对所观察的事物进行评价。



根据度量对数据集的聚集方式不同,度量可以划分为:

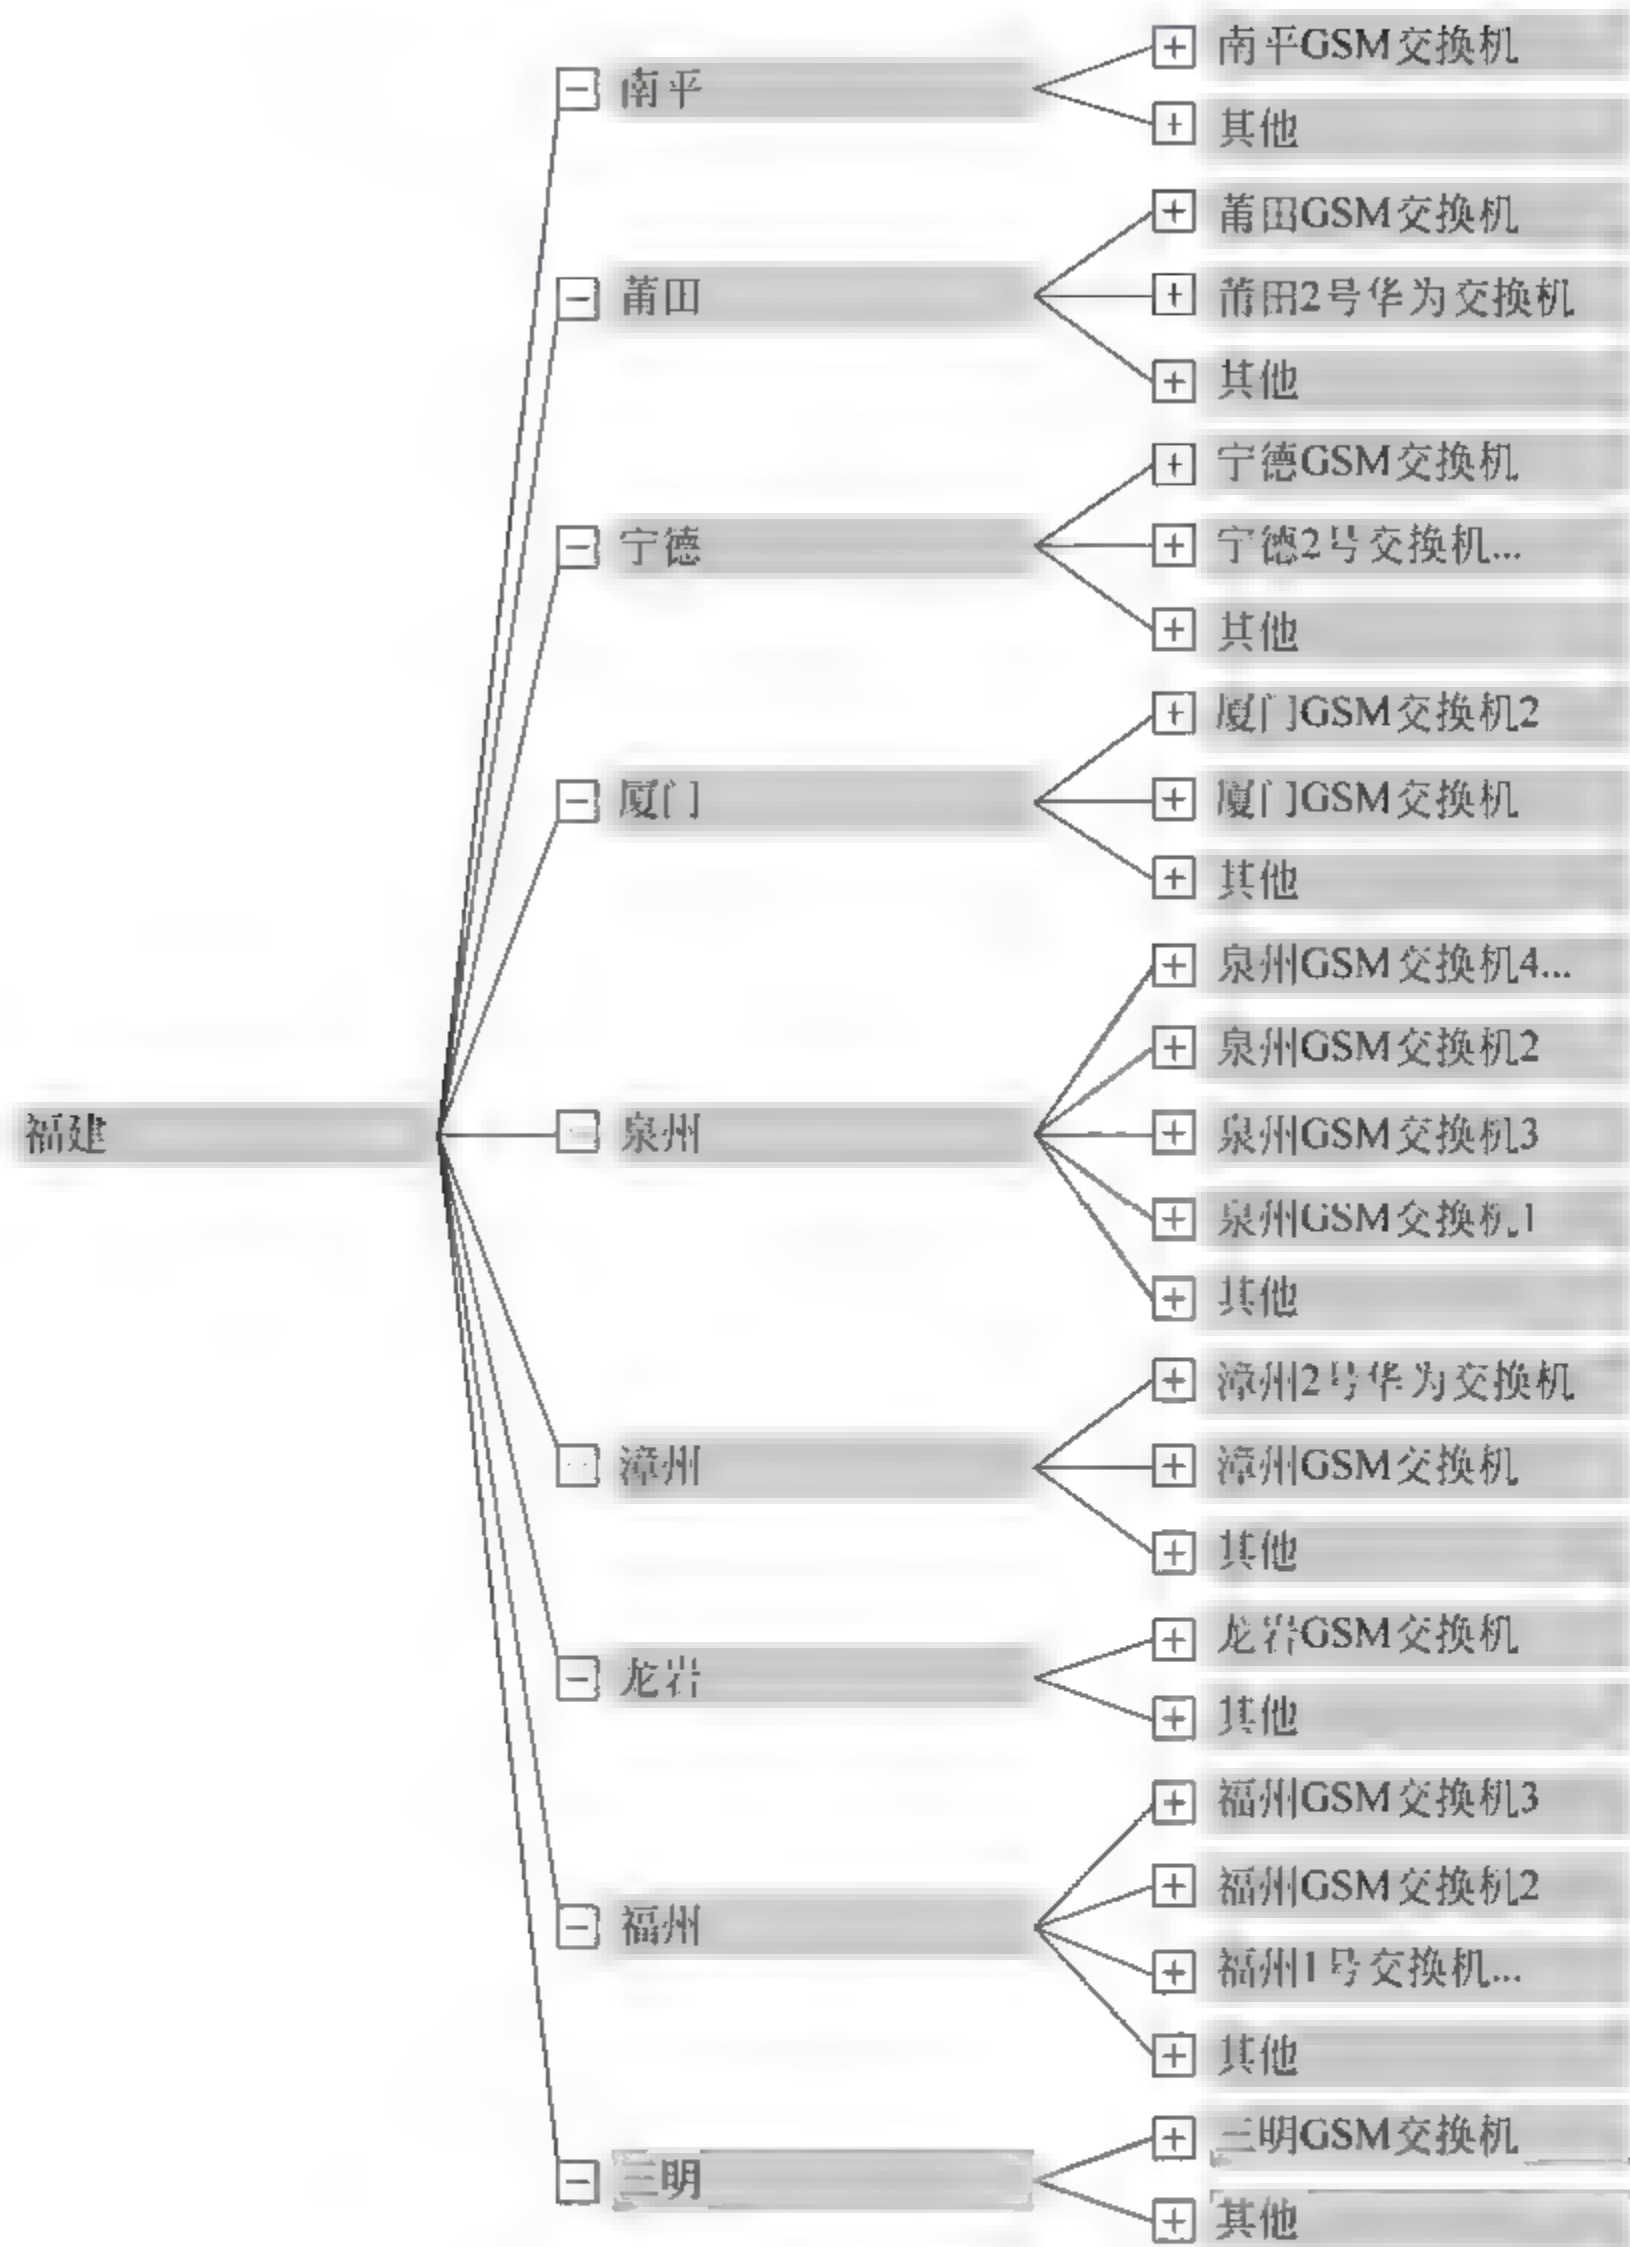


图 2.4 均衡的维度层次结构



图 2.5 非均衡的维度层次结构

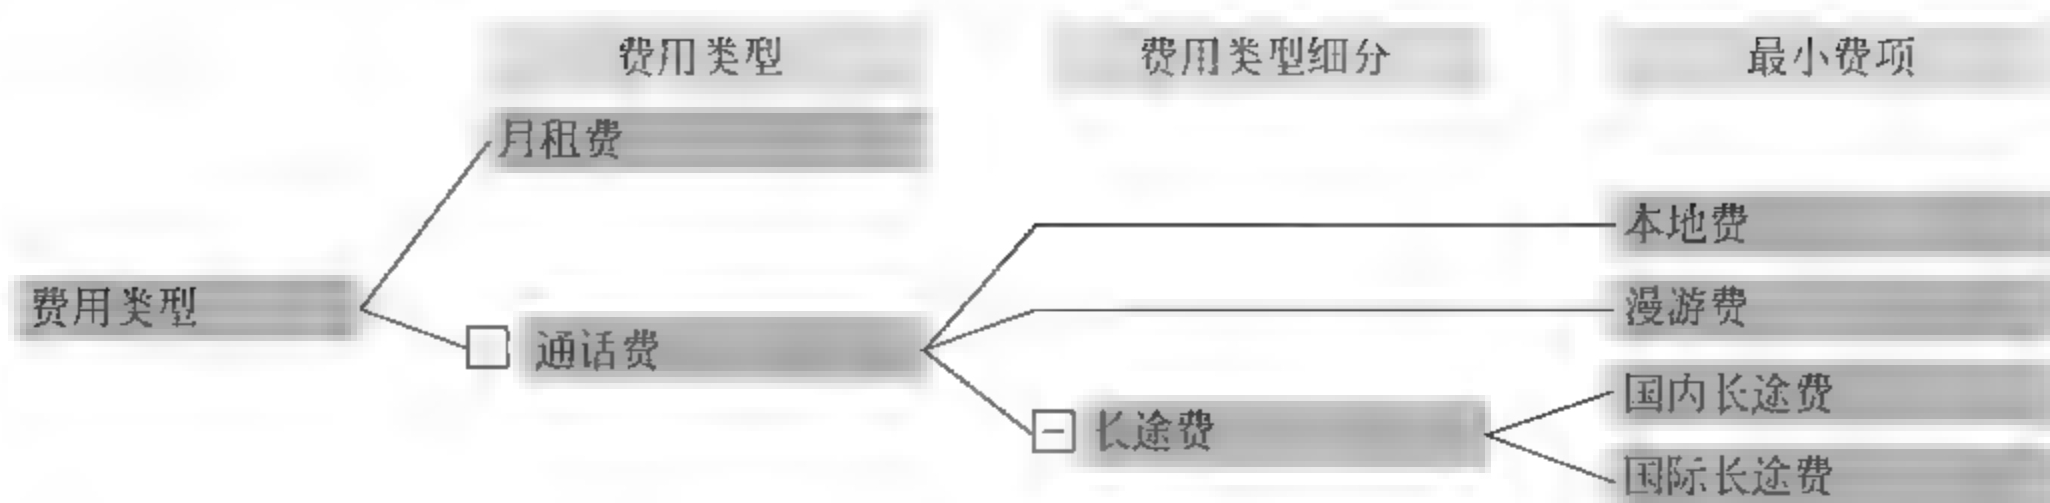


图 2.6 不整齐的维度层次结构

- 分布的：设数据被划分为  $n$  个集合，函数在每一部分上计算得到一个汇总值。如果将函数用于  $n$  个汇总值得到的结果，与将函数用于所有数据得到的结果一样则该度量是分布的。例如，在电信业务中通话费用这一度量就是分布的，这种形式的度量所应用的聚集函数一般是 `count()`、`sum()` 等。
- 函数的：如果聚集函数可以由一个具有  $M$  个参数的函数表示，且每个参数都可以用一个分布汇总函数求得，则该度量是函数的。如 `avg()` 可以由 `sum()/count()` 计算得到，其中 `sum()` 和 `count()` 都是分布汇总函数。月平均使用次数就是一个函数的度量。
- 整体的：如果一个聚集函数无法用具有  $M$  个参数的函数表示，则该度量是整体的，如 `rand()`、`count(distinct)` 等，例如使用业务的用户数就是一个整体的度量。

不同的维和度量是通过事实联接起来的。事实是对某类事件或某种状态的记录，例如一次通话或者业务受理等，事实一般都包括若干度量提供对事件的评价，例如通话这一事实包括通话时长、通话费用等度量。也有一部分事实不包括任何度量，它们反映了某类事件的发生，如“某人在某天被停机”。

Kimball 提倡的数据仓库的多维模型，一般也称为星型模式，有时也引入一些雪花模式。星型模式是为了将数据分割为执行起来容易理解的格式而设计的，它是一种多维的数据关系，由一个事实表 (fact table) 和一组维表 (dimension table) 组成。每个维表都有一个维作为主键，该主键链接到事实表，所有这些维组合成事实表的主键。事实表的非主属性称为事实 (fact)，一般都是数值或其他可以进行计算的数据，而维大都是时间、地域等。

① 事实表：每个数据仓库或数据集市都包含一个或多个事实表。星型模式或雪花模式的中心是一个事实表。通常，事实表包含大量的行，有时当事实表包含企业一年或几年的历史数据时，可能有数亿条记录。事实表的主要特点是包含数值数据 (事实)，而这些数值数据可以汇总以提供有关企业运营历史的信息。每个事实表还包含一个由多个部分组成的索引，该索引包含作为外键的相关维表的主键，而维表包含事实记录的特征。事实表不应包含描述信息，也不应包含数字度量字段，以及使事实与维表中的对应项相关的索引字段之外的任何数据。

② 维表：包含描述事实表中的事实记录的特征。有些特征提供描述性信息，有些特征用于指定如何汇总事实表数据以便为分析者提供有用的信息。维表包含有助于汇总数据的特性的层次结构。

数据仓库的负载主要有两种：一种是回答重复性的问题，另一种是回答交互性的问题。



对于以第一种负载为主的部门数据集市,当数据量不大、报表较固定时可采用多维模式;对于企业中心数据仓库,考虑到系统的可扩展性、投资成本和易于管理等诸多因素,可采用第三范式。

## 2) 模型比较

逻辑模型的设计既可以采用星型模式或雪花模式,也可以采用第三范式。

在数据库逻辑模型设计中有一个规范化的过程,以减少数据冗余。范式是衡量数据库规范化程度或深度的一种方法,具有非常严格的数学定义。根据数据规范化程度的不同,由低至高分为第一范式、第二范式、第三范式、Boyce-Codd 范式、第四范式和第五范式。对于一般的数据库系统而言,只做到第三范式,如果一个数据模型满足第三范式,就可以认为该模型的冗余度已经很低了。

在数据仓库逻辑模型设计中,采用第三范式可以达到:

(1) 减少数据冗余,减少数据的存储要求。

(2) 便于数据抽取。采用第三范式,减少了单表中的数据冗余,因此在进行数据装载时要比星型模式或雪花模式使用较少的关联操作,数据的装载速度较快,同时减少数据冗余也降低了数据之间的依赖关系,便于数据的并行抽取。例如电信企业数据仓库数据模型设计时,如果在欠费表中加入用户套餐等冗余信息后,在抽取欠费数据时必须首先等到用户数据和欠费数据同时准备好后才能开始抽取数据。

(3) 便于重用业务系统的数据模型,提高开发速度。

满足第三范式的数据模型在查询时,特别是针对 OLAP 应用的查询,需要进行的数据关联操作较多,查询效率低。而星型模式或雪花模式通过对事实表的预先汇总和引入冗余字段,提高了查询效率。但是进行数据汇总的操作会丢失一部分信息,因此数据汇总方式的选择应根据用户的查询需求,如果需求发生变化特别是需要增加新的观察维度时,则需要修改模型,甚至有时要重新装载数据。

数据仓库的数据组织可以分为历史细节级、当前细节级、轻度综合级和高度综合级四个层次,其中轻度综合级和高度综合级的数据都根据用户需求进行了一定程度的汇总,因此对轻度综合级和高度综合级的数据易于使用星型模式或雪花模式,以提高数据的访问速度。而对于当前细节级数据可以采用满足第三范式的数据模型以提供各种细节信息。

采用多维模型设计时需要注意的问题如下:

① 事实表的设计。事实表主要来自业务系统中的操作记录,例如电信业务中的通话、缴费和出账等,同时也有一部分事实表是对主题状态的记录,如用户停开机状态的记录。

在设计事实表时,应对事实表中包含的度量进行分类,如果该度量是一个整体度量,则需要对该度量生成不同汇总级别的事实表以保证数据的准确性。例如在通话行为中,如果有一个度量是通话用户数,它是一个整体度量,因此应对该度量生成不同汇总层次的事实表。在设计事实表时应尽量避免使用整体度量。

此外,还应注意将具有相同维度的事实表通过加入多个度量进行合并,以减少数据仓库中表的数量和数据冗余,但是在进行事实表合并的同时应兼顾数据的抽取效率,因为合并事实表常会导致数据抽取时需进行表之间的关联,例如如果将用户的欠费数据和销账数据合并为同一个事实表,则需要将欠费数据和销账数据按照用户标识进行关联形成一条记录后装载到事实表,这样将影响数据的抽取效率,一般对高度汇总级的数据进行事实表的合并。



② 维表的设计。维表主要来自于业务系统的各个实体以及实体的属性,同时还有一部分是根据用户需求生成的派生维。

一般不使用业务系统的主键作为维表的主键,维表一般选择无意义的顺序数字作为主键。这主要是为了保证对维表中数据变化的处理,同时也增加了维度层次组合的灵活性。由于业务系统都是通过主键进行关联,因此增加新的维表主键会导致在数据抽取时需要对数据进行转换,影响抽取效率。同时维表中应保存业务系统中的主键以标识业务系统同一意义的数据。

一般情况下,业务实体单独作为维表,不同实体之间的关联通过主、外键实现。对于用户定义的派生维通常需加入时间字段以保存用户定义的变更。

### 3) 逻辑模型设计

数据仓库的逻辑模型可以认为是数据仓库开发者和使用者之间就数据仓库的开发进行交流和讨论的工具与平台,同时对系统的物理实施具有重要的指导作用,通过实体和关系勾勒出整个企业的数据蓝图。

逻辑模型设计主要包括:

(1) 分析主题域。在概念模型设计中,确定了几个基本的主题域。但是,数据仓库的设计是一个逐步求精的过程。一般是一次一个主题或一次若干个主题逐步完成。所以必须对概念模型设计步骤中确定的几个基本主题域进行分析,选择首要实施的主题域。选择主题域所要考虑的是其应足够大,以构建一个可应用的系统;它还要足够小,便于较快地开发和实施。

(2) 数据粒度层次划分。数据仓库逻辑模型设计的一个重要问题是数据仓库的粒度层次划分,其适当与否直接影响到数据仓库的数据量和所适合的查询类型。一般需要将数据划分为详细数据、轻度综合、高度综合三级或更多级的粒度。粒度层次的划分是由数据的行数决定的,数据行数越多,所需存储空间越大,粒度划分的级别就越多。

(3) 数据分割。数据分割是提高数据仓库性能的重要手段,它将逻辑上是统一整体的数据分割成较小的、可以独立管理的物理单元进行存储,以便于重构、重组和恢复,提高创建索引和顺序扫描的效率。确定分割策略主要是指选择适当的数据分割标准,一般应考虑以下因素:数据量、数据分析处理的要求、简洁性以及粒度划分策略等。其中,数据量的大小是决定是否进行数据分割和如何分割的主要因素;数据分析处理的要求是选择数据分割标准的一个主要依据,因为数据分割与数据分析处理的对象紧密联系,设计者还需考虑到所选择的数据分割标准应是自然的、易于实施的,同时也应考虑到数据分割标准与粒度层次划分是相适应的。

(4) 关系模式定义。数据仓库的每个主题都是由多个表实现的,这些表之间以主题的公共码键关联在一起,形成一个完整的主题。在概念模型设计时,确定了数据仓库的基本主题,并对每个主题的公共码键和基本内容等进行描述,即对选定的当前实施的主题进行模式划分,形成多个表,并定义各个表的关系模式。

### 4) 数据粒度

数据粒度是指数据仓库中保存数据的细化或综合程度的级别。细化程度越高,粒度越小;反之,细化程度越低,粒度越大。数据粒度的确定对于数据仓库数据模型的设计非常重要,主要原因在于:



(1) 数据仓库保存业务系统的历史数据,随着时间的推移,数据不断增加,数据仓库保存了大量数据。在有限的直接存储设备上保存这些信息,同时又能够较快地响应用户查询,如果仅保存细节数据,将减少数据的在线保留周期,而且数据查询的效率也会降低。

(2) 用户的分析型操作大部分是针对汇总信息的查询和数据趋势的观察,如果仅保存细节数据,则完成分析型操作时需要遍历大量数据,对系统的软硬件要求都很高。

实际上,数据仓库的数据是按照不同粒度保存的。确定数据粒度旨在延长有效数据的在线保存时间,提高查询效率。

确定数据粒度时,需要考虑以下问题:

(1) 确定是否使用多重粒度。

单一粒度和多重粒度的主要区别是在数据的冗余存储,而不是指是否对数据进行汇总,单一粒度和多重粒度都存在汇总数据。单一粒度是指在数据进入数据仓库时先保存为细节数据,当数据的保留周期到期时,对细节数据进行汇总形成综合数据,同时将细节数据导出到其他慢速存储设备上,单一粒度中细节数据和汇总数据之间逻辑上没有重叠;多重粒度是指数据在进入数据仓库时,同时以细节数据和汇总数据存在,当数据的保留周期到期时,将细节数据导出。多重粒度中细节数据和汇总数据有一部分是重叠的。对于细节数据量较大的数据仓库而言,如果以单一粒度存储,对近期数据的查询效率较低。因此,对这类数据仓库建议采用多重粒度存储。

确定是否需要使用多重粒度,需要对数据仓库保存的数据量进行估算,W. H. Inmon 给出了数据量估计的计算公式。

对每个已知表  $i$  计算:

- 估算一行所占字节数大小的最大值  $L_i$  和最小值  $l_i$ 。
- 统计一年内可能出现的数据行数的最大值  $M_i$  和最小值  $m_i$ 。
- 统计五年内可能出现的数据行数的最大值  $N_i$  和最小值  $n_i$ 。
- 计算每个表键码的字节数  $K_i$ 。

一年内数据量估计为:

$$\text{最大值} = \sum (L_i + K_i) \times M_i$$

$$\text{最小值} = \sum (l_i + K_i) \times m_i$$

五年内数据量估计为:

$$\text{最大值} = \sum (L_i + K_i) \times N_i$$

$$\text{最小值} = \sum (l_i + K_i) \times n_i$$

根据估算的数据量,参照表 2.1 所示的对照表,确定是否使用多重粒度。

表 2.1 不同数据量级与数据粒度的对应关系

1 年内数据量/行	5 年内数据量/行	数据粒度策略
10000	100000	设计简单
100000	1000000	采用单一粒度
1000000	10000000	最好采用多重数据粒度
10000000	20000000	必须采用多重数据粒度



除了数据量外,是否使用多重粒度还应考虑细节数据的保留周期。如果细节数据的保留周期较长,可考虑使用多重粒度以保证数据的查询效率。值得注意的是不同行业、不同用户的需求可能导致不同的细节数据保留周期。

(2) 确定粒度级别。确定粒度级别是指确定数据仓库中汇总数据的汇总程度,数据越详细,数据粒度越低。如果数据汇总程度较低,则需要大量的资源处理数据;如果数据汇总程度较高,则会降低查询的灵活性。

如前所述,数据仓库的数据组织层次分成历史细节级、当前细节级、轻度综合级和高度综合级。一般而言,历史细节级和当前细节级保存的都是最低粒度的数据。对粒度级别的选择主要针对轻度综合级和高度综合级而言,以便大部分查询可以在轻度综合级或高度综合级完成。

确定粒度级别,需要对用户需求和实际存储设备容量综合考虑。众所周知,数据仓库的开发是一个反复的过程,因此数据粒度级别也需要和最终用户反复交流确定。如果用户对最终展示数据要求更详细则要降低粒度,反之如果用户对轻度综合数据的查询大部分是数据汇总操作,可以适当提高粒度级别,以提高用户查询响应速度。

确定粒度级别时需要注意的问题是:

- 对数据进行汇总时一般应保留主题对应的公共键码,同一主题下的数据是通过主题的公共键码关联的。
- 选择粒度级别时,考察汇总后生成的某些衍生字段的汇总方式。例如在产品主题中对一天中产品的使用情况进行汇总,可以得到每天不同产品使用的用户数,但是用户数对时间而言不存在有规律的汇总方式(或者说是整体的),对这种衍生字段必须提供多个不同粒度的汇总数据。

(3) 选择数据汇总方式。在确定数据粒度时要选择数据汇总方式,可供选用的数据汇总方式主要包括:

① 按维汇总。由上述的多维模型可知,维是用户观察数据的角度,对应关系模型而言就是表中的某个字段。维是有层次的,按维汇总是指选取一个维度,将数据按照维的不同层次进行汇总,这是最常用的数据汇总方式。例如电信业务的通话详单数据中可以按时间维进行汇总,从而得到某天某用户的通话总次数、总时长;再对一个月内的用户通话进行汇总,从而得到一个月内一个用户的通话总次数、总时长,进而再汇总到年。时间维是经常用来进行汇总的一个维度。

按维汇总时,还可以考虑用户观察数据的其他角度,加入其他维。但是如果维度过多,将会影响数据的汇总效果。此时,可同时进行模式转换的汇总。例如,电信业务话单的通话级别维标志该条话单是本地还是长途通话,采用按照时间维的不同层次进行数据汇总,如果加入的维很多,可以删除通话级别维,加入本地通话次数、长途通话次数字段。

② 提取数据子集。提取数据子集是根据用户的分析需求,因为用户可能只对一个数据集合中某个数据子集感兴趣,因此可以通过数据过滤,只保留部分数据供用户查询和分析,从而降低存取的数据量。例如,电信业务话单中,用户只对入网一个月以内的用户通话数据感兴趣,可以提取这部分细节数据供用户分析使用,其他数据通过汇总保存在较高粒度级别。



③ 变更数据模型。通过改变数据模型对数据进行汇总,将某些分类信息转换成字段存储。例如电信用户账单中保存的是每个月每个用户在不同费项上发生的费用,因此该表的主键是月份、用户标识和费项类型,这样数据行数较多,可以通过改变数据模型,即删除费项类型,加入不同费项类型的费用字段,这样表的主键是月份和用户标识,数据行数将明显减少。

④ 建立广义索引。广义索引是指对数据集中的数据特征进行统计,这样用户仅需要查看统计结果就可以了解数据的大致情况,统计方法包括最大最小值、数据平均值和排序等。例如针对电信业务的欠费,可以建立本月欠费前 100 名的用户以便查询。

建立广义索引是基于用户的查询需求,通过对用户经常需要回答问题的了解,可以为用户建立相应的广义索引,提高查询效率。

数据仓库中,数据粒度之所以重要,是因为它深深地影响数据仓库数据量的大小,以及数据仓库所能回答的查询类型。实际中,我们需要在数据仓库的数据量大小和查询的详细程度之间进行权衡。

图 2.7 所示为两个粒度不同的数据仓库,图的左侧是低粒度的数据仓库,每次通话都被详细记录下来,到月底每个客户平均有 200 条记录(当月每个电话都记录一次),因此共需 40000 个字节;图的右侧是高粒度的数据仓库,数据代表每个客户一个月的综合信息,每个客户一个月只有一条记录,这样的记录大约只需 200 个字节。当提高数据粒度级别时,数据仓库所能回答查询的能力会随之降低。换言之,在一个很低的粒度级别上可以回答任何问题,但在高粒度级别上所能回答的问题是有限的。

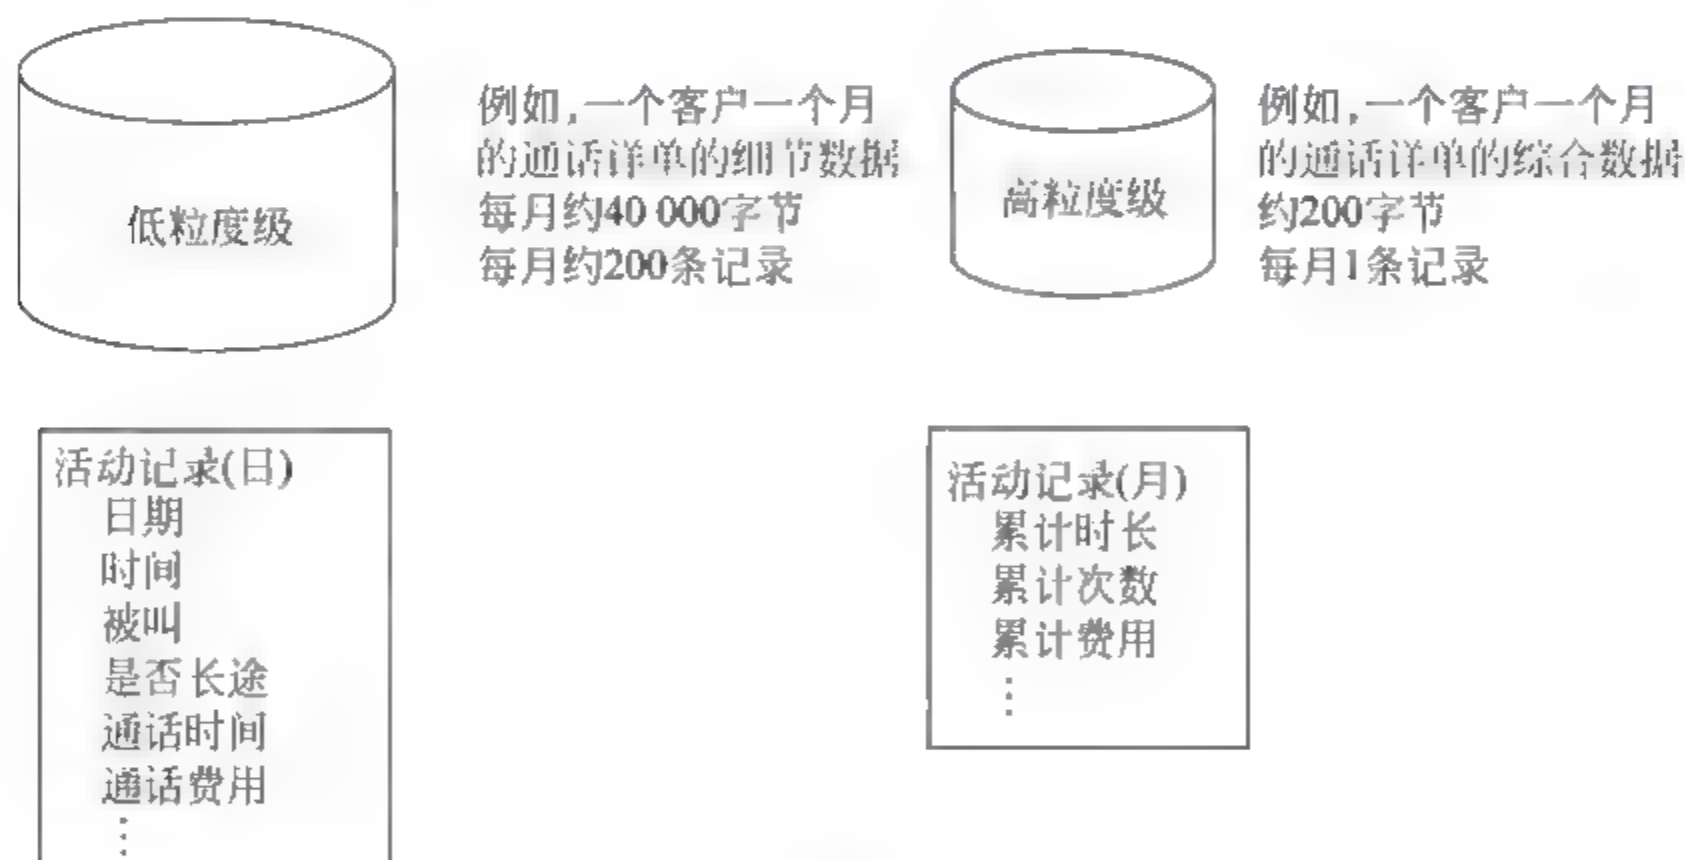


图 2.7 不同粒度的数据仓库

针对图 2.7,问“上星期某某客户是否给某某人打了电话?”。在低粒度级别上,这一问题是可以回答的,虽然这种回答将花费大量开销去查询大量的记录,但查询结果是确定的。然而,在高粒度级别上则无法明确地回答这一问题。因为在数据仓库中存放的只是当月所拨打电话的总次数,无法确定其中是否有一个电话是打给某人的。

但是,DSS(数据仓库环境中常见)很少对单个事件进行查询,通常是针对某种数据集合进行处理,这意味着需要查询大量记录。例如“上个月客户从某地呼出的长途电话平均多少个?”,对 DSS 而言这类查询是很常见的。当然,它既可以在高粒度级别也可以在低粒度级别上得到回答。值得注意的是,不同的粒度级别上所使用的资源具有相当大的差异。在低



粒度级别上回答这一问题需要查询每条记录,所以需要大量的资源。但在高粒度级别上,数据进行了很大的压缩。

显然,如果数据仓库的存储空间很有限,高粒度级别要比低粒度级别的效率高得多。

高粒度级别的数据仓库不仅占用的存储空间少得多,而且需要的索引项较少。然而不仅要考虑数据量和存储空间的问题,为了访问海量数据处理能力同样也是一个考虑的要素,所以数据仓库中数据压缩非常有用。数据压缩会大大节省所占用的存储空间,节省所需的索引项以及处理器资源。

综上所述,对于数据粒度的权衡,在数据仓库设计时必须仔细加以考虑。

#### 5) 数据分割

数据粒度是通过数据汇总减少数据量,提高数据的存储效率和查询效率。但是这并不能解决同一粒度下由于数据量过大导致的数据查询效率较低的问题。对于这类问题需要使用数据分割技术。数据分割是指将数据分散到各自的物理单元以便能够独立处理,提高数据处理效率。数据分割后的数据单元称为分片,分片数据没有交叉。

数据分割的意义在于:

- 提高查询速度。通过分割,降低查询的数据量,同时将大表分割成若干小表,易于建立表索引。
- 便于数据重组。数据重组是指将数据按照一定的规则进行新的组合,例如将电信业务话单表分割成每月一张表,用户可能按照一定的规则将月份分成几组,这样当查询某个组的数据时只要扫描该组中月份对应的表,数据量相对较小。
- 便于表维护。通过数据分割,降低单表的数据量,减轻数据维护的工作量。
- 增加系统并行性。数据分割可以增加数据抽取和查询的并行性。

数据仓库中,数据分割的关键问题不是该不该分割而是如何分割。

数据分割的主要工作是选择分割的标准,数据分割并没有固定的标准,应根据用户的需求和数据使用方式共同确定数据分割标准。

选择数据分割标准需要考虑的主要因素如下:

(1) 数据分割尽量均匀。数据分割旨在将数据量较大的数据分割成若干小的分片以提高查询速度,因此选择数据分割的标准应尽量保证数据在各个分片中的分布较均匀。例如,对通话详单可以按照时间进行分割,由于每天通话的次数相差不多,对某天通话进行查询时可以获得较高的查询速度。

(2) 用户的查询需求。在选择数据分割标准时应考虑用户的查询需求,以便将用户的大部分查询在一个分片内完成,达到提高系统性能的目的。例如,用户在查询账单时经常按照用户所属地市进行查询,因此对账单按照用户所属地域进行分割,这样用户大部分查询可以在一个地市的账单表中完成。但是,如果数据分割的标准改为按用户标识的末尾数字,则用户在查询一个地区的账单时需要扫描全部分片,这样查询效率要比不进行数据分割还低。因此,数据分割一般按照某个维度的一个层次的取值,常用的维是时间、地域和产品等。

(3) 数据汇总的方式。数据分割还应考虑数据汇总方式,如前所述,选择高粒度级别可减少数据量,同时提高用户查询的速度,因此在对低粒度级别数据进行分割时还应考虑数据汇总到高粒度时的汇总方式,一般选取的数据分割标准是高粒度级别中的某个维度。

(4) 易于数据重构。数据重构是数据分割的反操作。易于重构是指采用分割标准进行



分割的数据易于组成整体以满足用户的查询需求。

数据分割标准是严格地由开发人员选择的。然而,在数据仓库中,日期几乎是分割标准中一个必然的组成部分。

数据分割可以在应用层也可以在系统层。系统层的数据分割一般是依赖 DBMS 或操作系统提供的功能,不同的 DBMS 提供的数据分割方法也不同。而应用层的数据分割主要是按照一定的规则,将数据分割为若干逻辑小表。在逻辑模型设计时考虑的数据分割是应用层的。

数据仓库开发人员面临的主要问题之一是在系统层还是在应用层进行数据分割。在系统层进行数据分割在一定程度上是 DBMS 和操作系统提供的功能。在应用层进行数据分割则是由应用程序代码完成的,这是由开发者和程序员严格控制的。当在应用层进行数据分割时,DBMS 和系统无法知道一种分割与另一种分割之间的关系。

通常,在应用层进行数据分割是很有意义的。最为重要的是在应用层上每年的数据可以有不同的定义。不同年份的数据定义,可以相同也可以不相同(例如不同版本)。在系统层进行数据分割时,DBMS 不可避免地希望只有一种数据定义。假如数据仓库中保存的数据时间较长(如达到十年),并且数据定义经常变化,让 DBMS 或操作系统去管理一个本该只有一种数据定义的系统将是毫无意义的。

在应用层进行数据分割的另一重要特点是它能从一个处理集转移到另一个处理集而没有损失。在数据仓库环境下,当负载和数据量成为真正的负担时,这一特点则是一种真正的优势。

对于数据分割而言,最严峻的挑战是能否在分割中加入索引而不会明显地影响其他操作。如果一种索引可随意加入,则分割是十分理想的;否则分割还需更精细些。

数据分割的主要实现手段包括:重构、自由索引、顺序扫描(可选的)、重组、恢复和监控等。

如果数据粒度和数据分割设计得很好,几乎所有的数据仓库设计和实现的其他问题都将迎刃而解;否则难以真正实现。

## 6) 数据划分

数据划分与数据分割不同,数据分割对关系模型而言是指对元组的划分,而数据划分是指对实体的属性按照一定的分组原则划分为不同的属性组,即数据模式的分解。一般地,数据划分针对主题对应的实体以及各个与主题相关的业务实体。

逻辑模型设计中进行数据划分的主要原因在于:

(1) 从数据存储角度看,实体中有的实体属性更新较为频繁,而其他属性更新频率较低。由于数据仓库要保存业务系统的变更历史,因而对于每次属性的变化,数据仓库一般采用新建记录的方式进行记录,这样如果将变化频率不同的字段放在同一张表中,将浪费较多的存储空间。

(2) 从数据访问角度看,表中的部分字段是经常被访问的,而其他字段访问较少,如果将所有字段存放在一张表中,则表会增大,影响数据访问速度。

基于上述原因,在逻辑模型设计时需考虑对表进行划分,采用的标准主要是按照字段变化频率划分和按照业务规则划分。

① 按照字段变化频率划分。根据字段的变化频率,将表中的字段分成“比较稳定”、“有



时变化”和“经常变化”三类,相应地将表拆分成变更频率不同的三个子表,例如电信用户资料表的各字段按照稳定性划分如图 2.8 所示。

比较稳定	有时变化	经常变化
用户标识	用户标识	用户标识
用户号码	用户套餐	用户状态
入网方式	用户信用额度	费用余额
受理点		
入网时间		

图 2.8 按照字段变化频率划分的实例

按照字段变化频率对表进行划分后,数据的存储空间占用较少。

② 按照业务规则划分。按照业务系统的业务规则将字段分成共有数据和专有数据。W. H. Inmon 提出了数据项集合(Data Item Set,DIS)方法对表进行划分。DIS 方法将数据分成初始数据、二次数据、联接数据以及各种数据类型。其中,初始数据是指主题中仅出现一次的属性,例如客户标识、入网时间等;二次数据是指关联实体的属性,例如产品名称等,一般是一些描述字段;联接数据是指本主题与其他实体间的关联,例如客户和产品等。数据类型是指按照业务规则对实体进行分类,可以看成是类的继承关系,例如客户按照消费程度可以分为大客户、普通客户;按照所处的状态可以分为停机客户、正常客户和离网客户等。可以对实体按照不同的标准进行分类,不同分类之间是组合的关系,如图 2.9 所示。

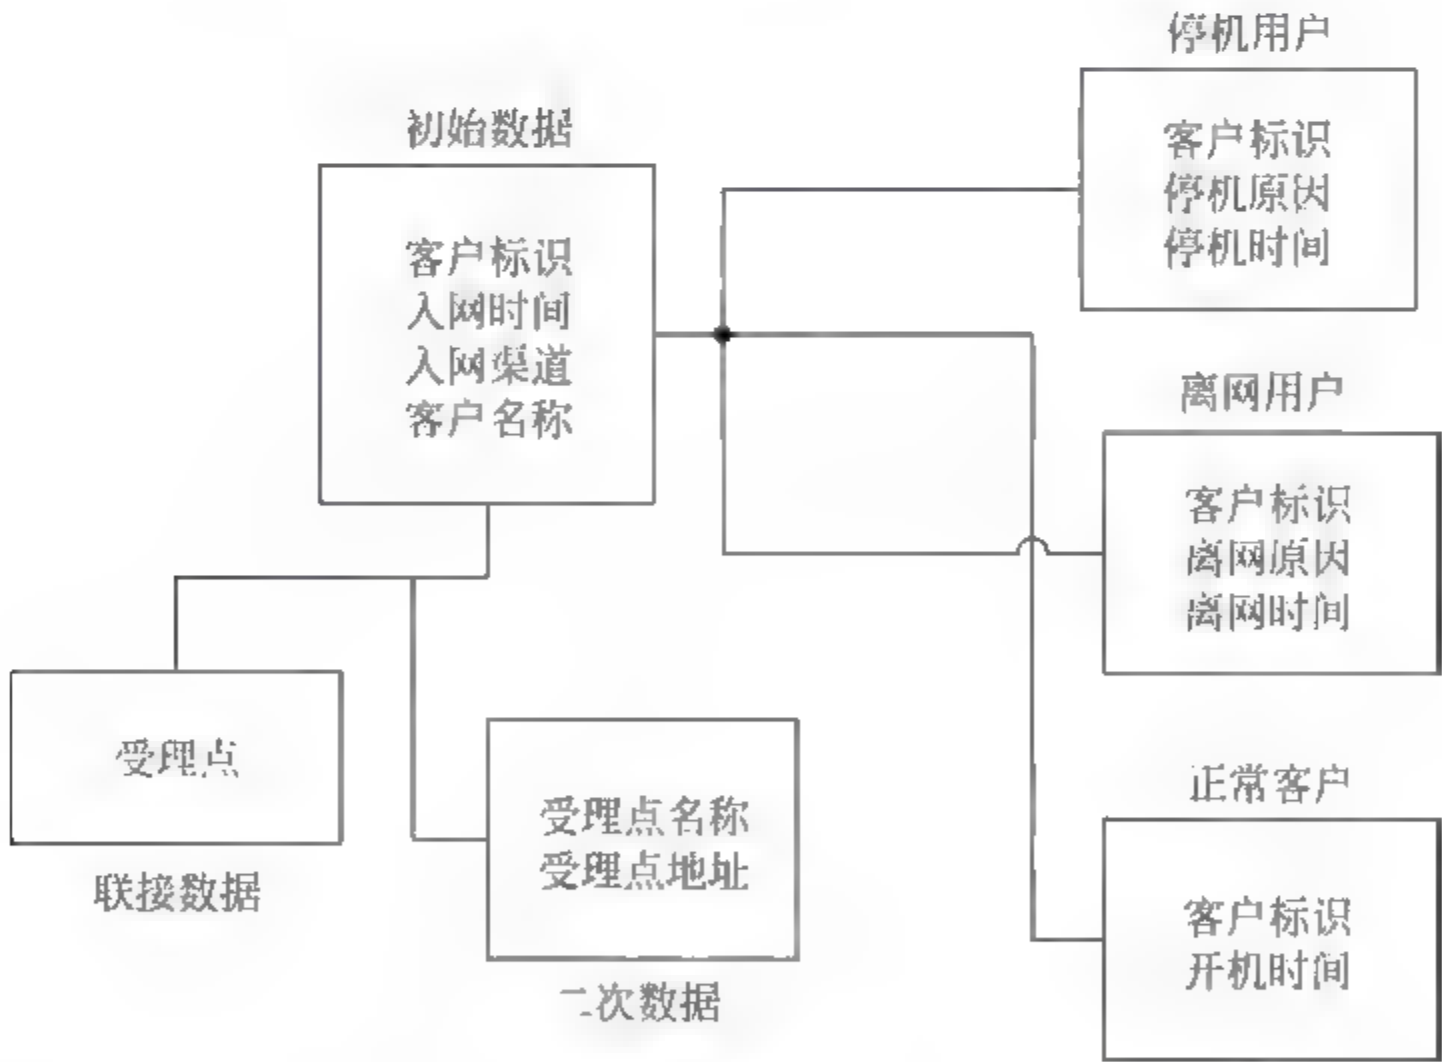


图 2.9 按照业务规则划分的实例

按照业务规则对数据进行划分,有利于数据访问。

7) 数据模式

数据仓库的数据模式包括星型、雪花型和星型 雪花型,三者都是以事实表为中心,不同之处只是外围维表之间的关系不同而已。



### (1) 星型

星型模式的每个维度都对应一个唯一的维表,维的层次关系全部通过维表中的字段实现,所有与某个事实有关的维,都通过该维度对应的维表直接与事实表关联,所有维表的主键组合起来作为事实表的主键,如图 2.10 所示。星型模式的维表只与事实表发生关联,维表与维表之间没有任何关联,具体实例如图 2.11 和图 2.12 所示。




图 2.10 星型模式示意图

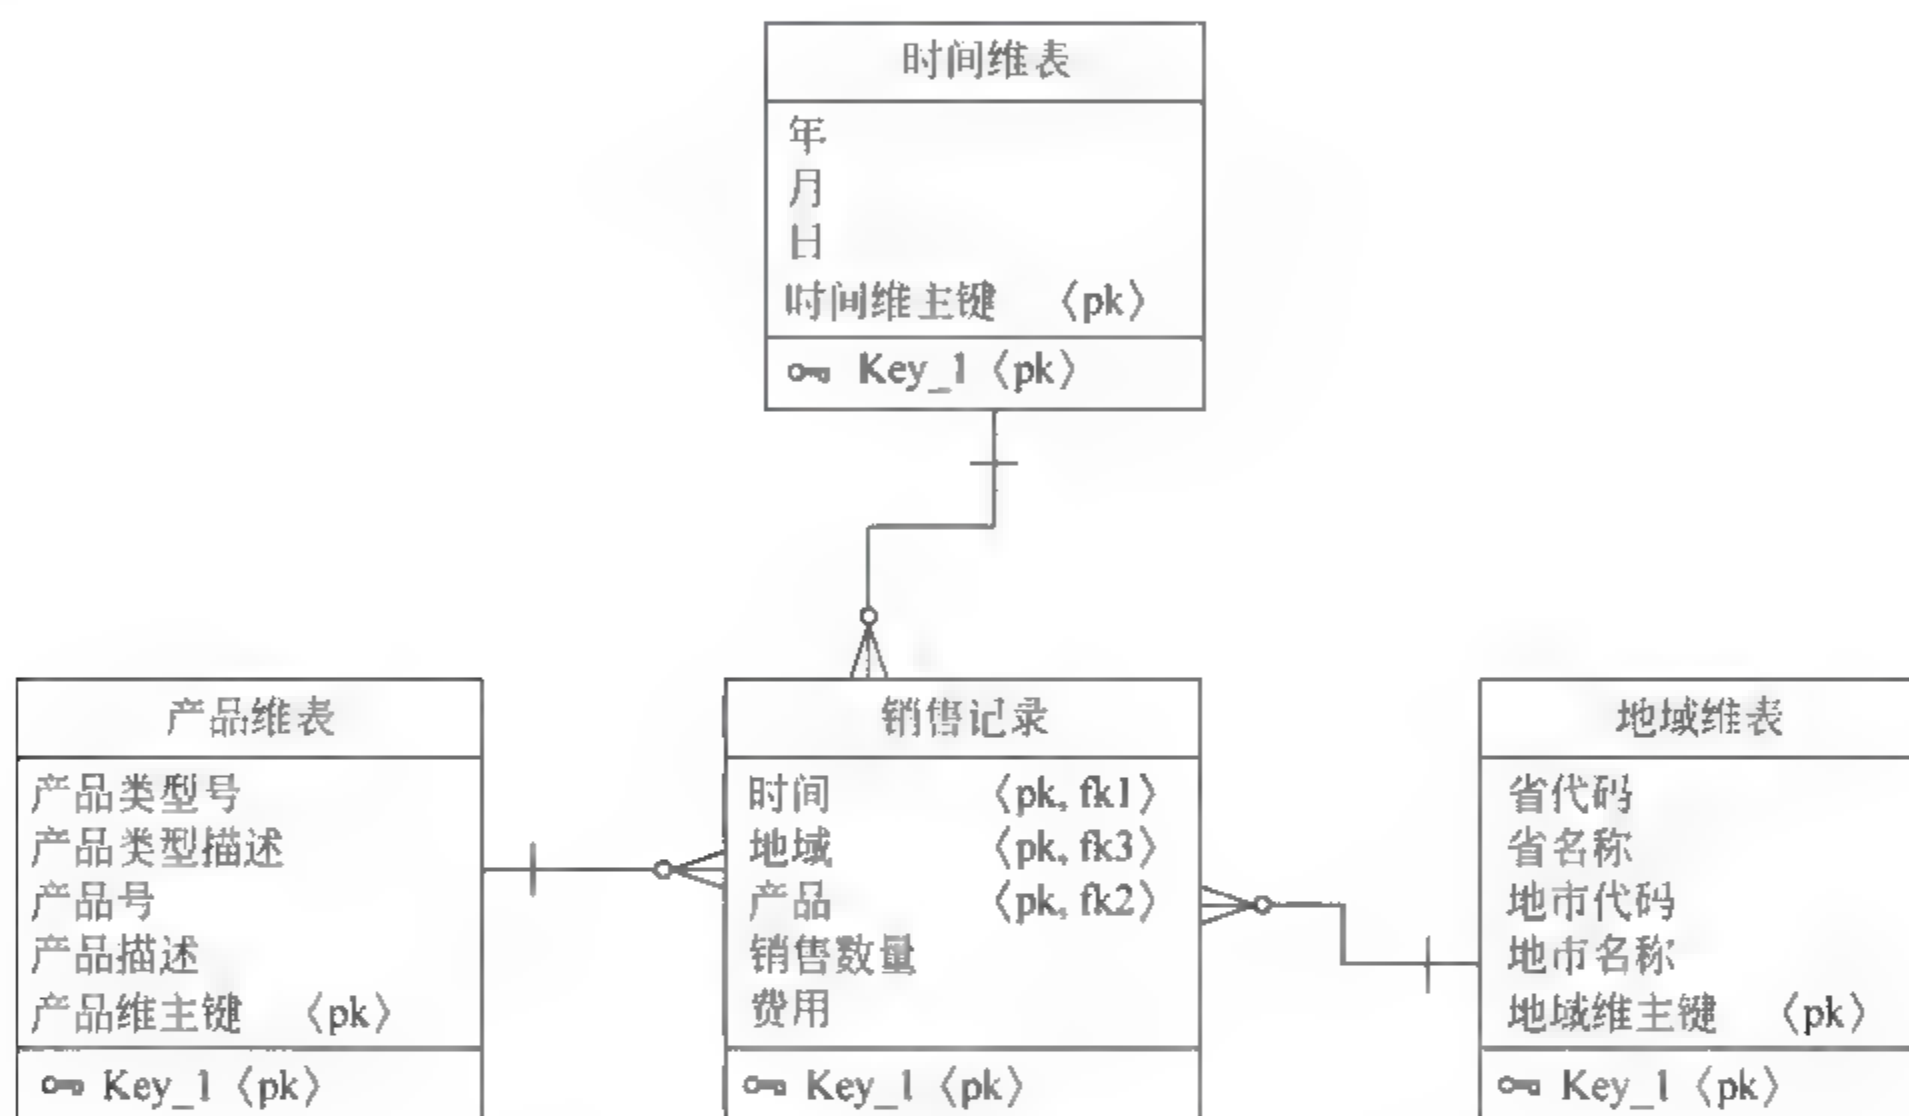


图 2.11 星型模式实例一

图 2.11 中,地域维是一个与销售事实表关联的维度,地域维的层次是“省—地市”,这一层次关系由维表中的省代码和地市代码字段实现。

星型模式的特点如下:

#### ① 维表的非规范化

星型模式中,维表保存该维度的所有层次信息,因此是非规范化的,这样减少了查询时数据关联的次数,提高查询效率。但是由于维表保存所有的层次信息,使得维表之间的数据共用性较差,例如电信业务中基站和受理点两个维的层次关系分别是“地市—区县—基站”和“地市—区县—受理点”,这两个维度中都有地市和区县,但是由于所有的层次信息都保存在各自的维表中,因此地市和区县分别保存在两个维表中,同一信息之间的统一是通过人工维护的。

#### ② 事实表的非规范化

星型模式中,所有维表都直接和事实表关联,因此事实表也是非规范化的,这样减少了查询时数据关联的次数,提高查询效率。但是采用这种方式也限制了事实表中关联维表的数量,如果关联的维表数量过多将会造成数据大量冗余,同时对事实表进行索引也很

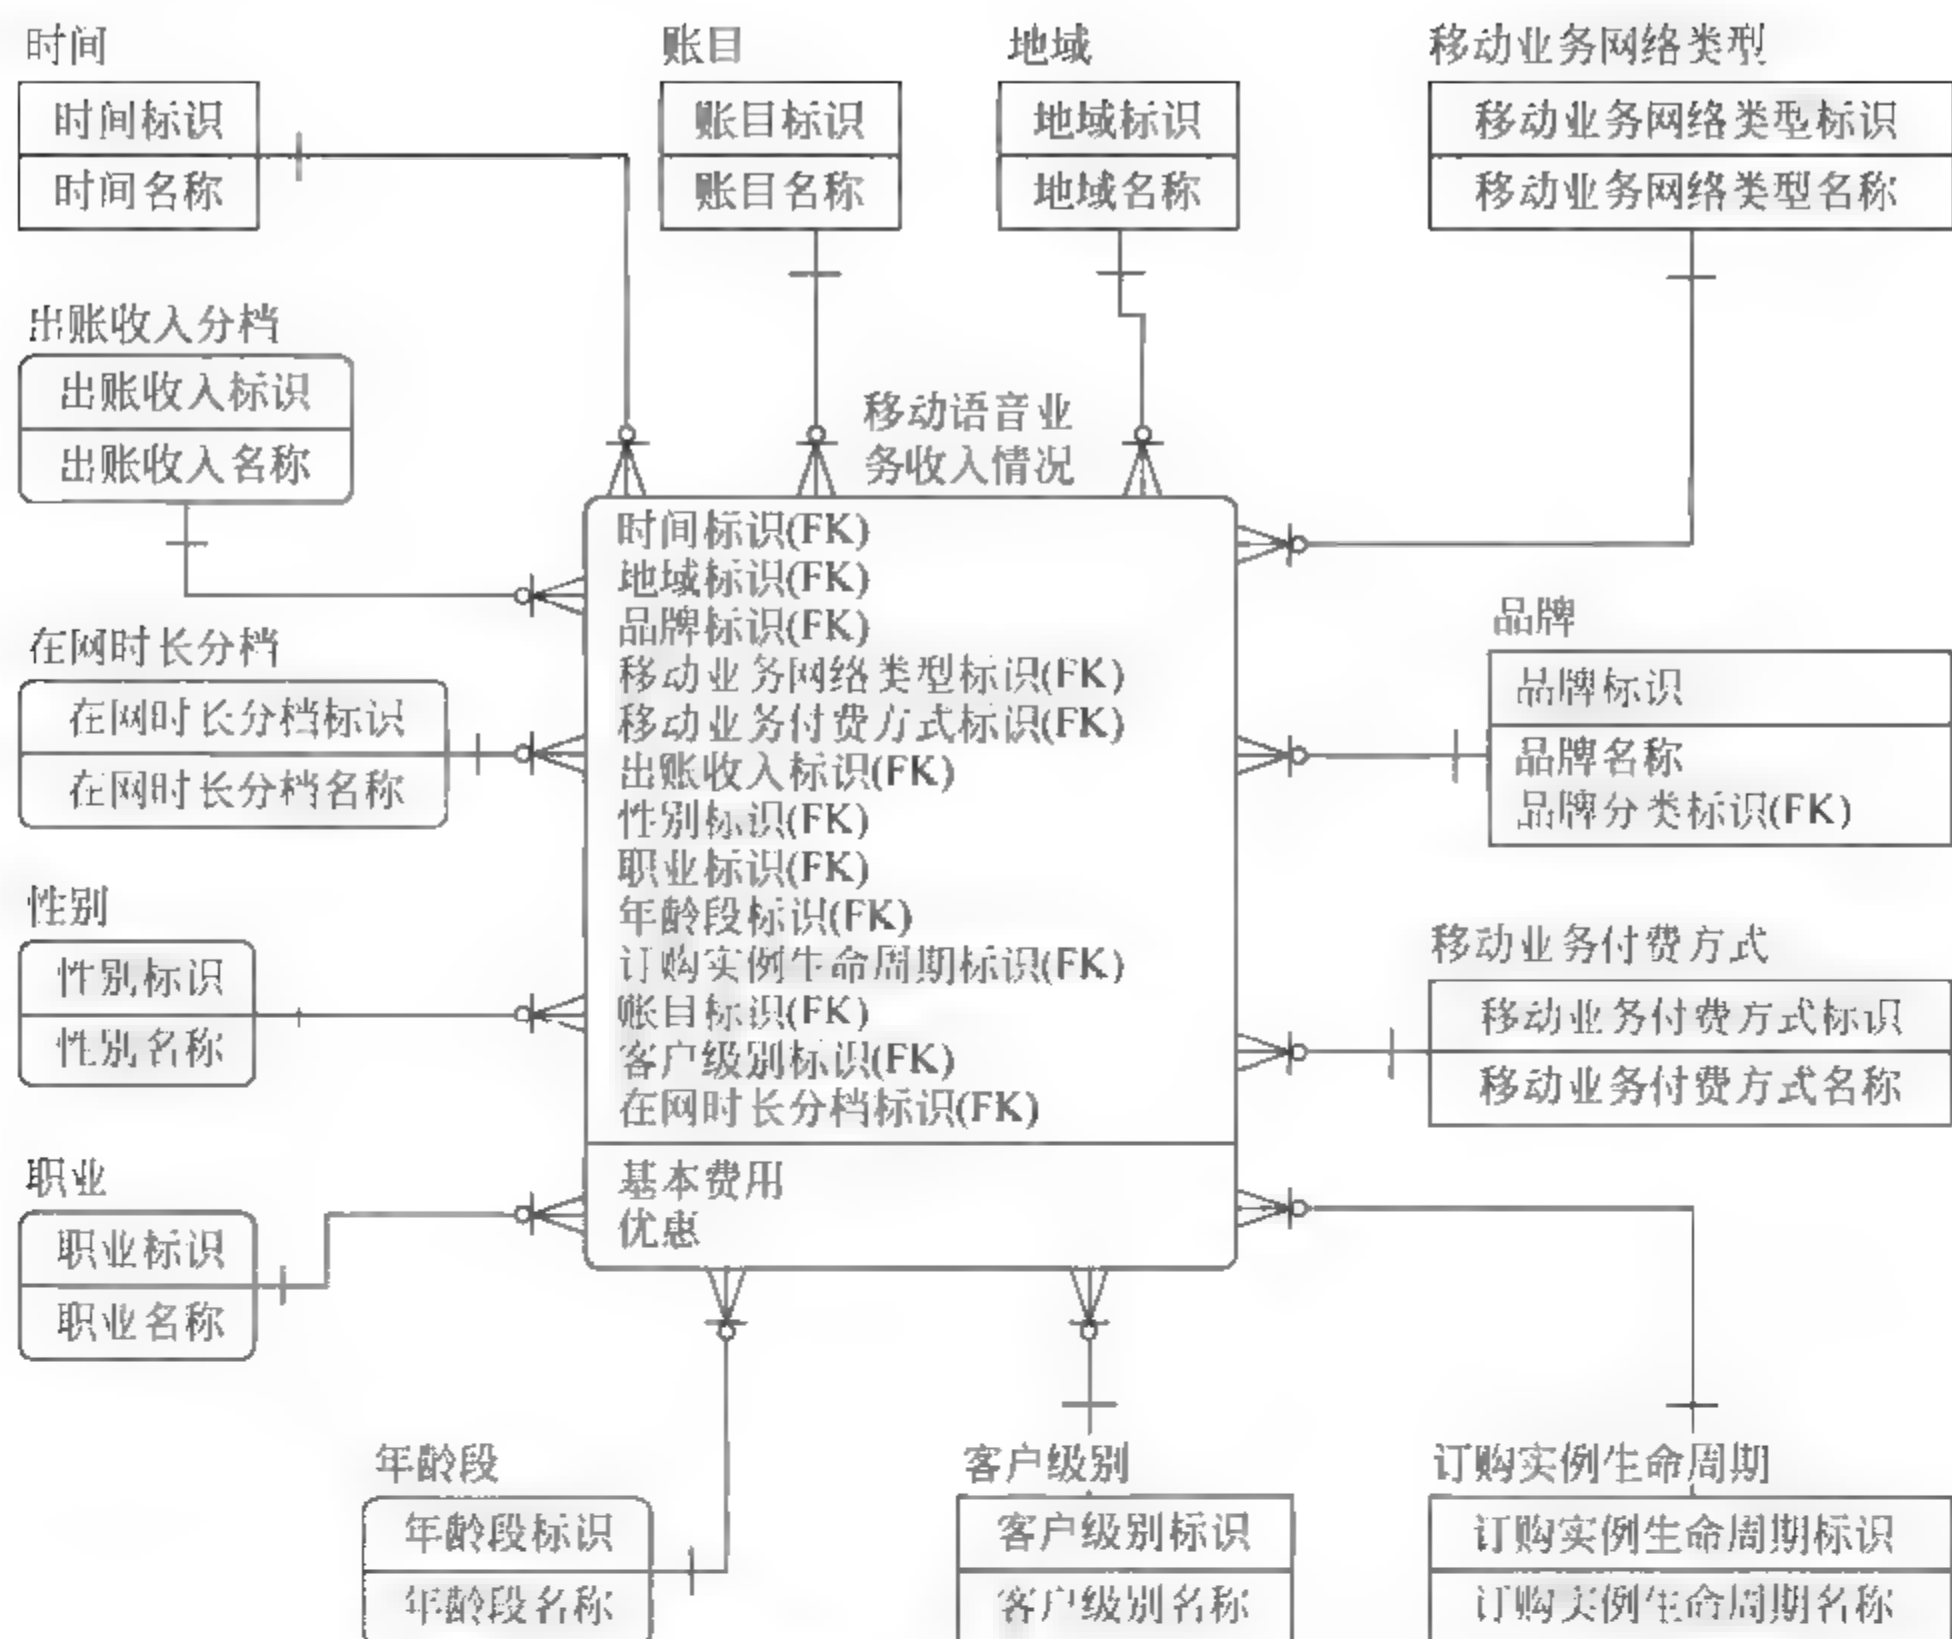


图 2.12 星型模式实例二

困难。

### ③ 维表和事实表之间的关系

星型模式中,维表中的主键在事实表中作为外键存在,因此维表和事实表的关系是一对多或一对一。如果维表和事实表之间是多对多的关系时,则不能直接采用星型模式,必须对维表或者事实表进行处理,如对维表中的成员组合进行编码或者在事实表中加入新的字段,但这都要求成员的组合数量固定,如果数量不固定,同时维表的数据量又很大的情况下,星型模式的实现较为困难。

### (2) 雪花型

事实上,维表只与事实表关联是正规化的结果。如果将经常合并在一起使用的维度进行正规化,即所谓的雪花型模式,如图 2.13 所示。同星型模式相比,雪花型模式的最大区别是对维表的规范化,即用不同维表之间的关联实现维的层次,具体实例如图 2.14 所示。

图 2.15 所示为对于上述基站和受理点的例子使用雪花型模式加以实现。

雪花型模式的特点如下:

#### ① 通过维表的规范化实现维表重用,简化




图 2.13 雪花型模式的示意图



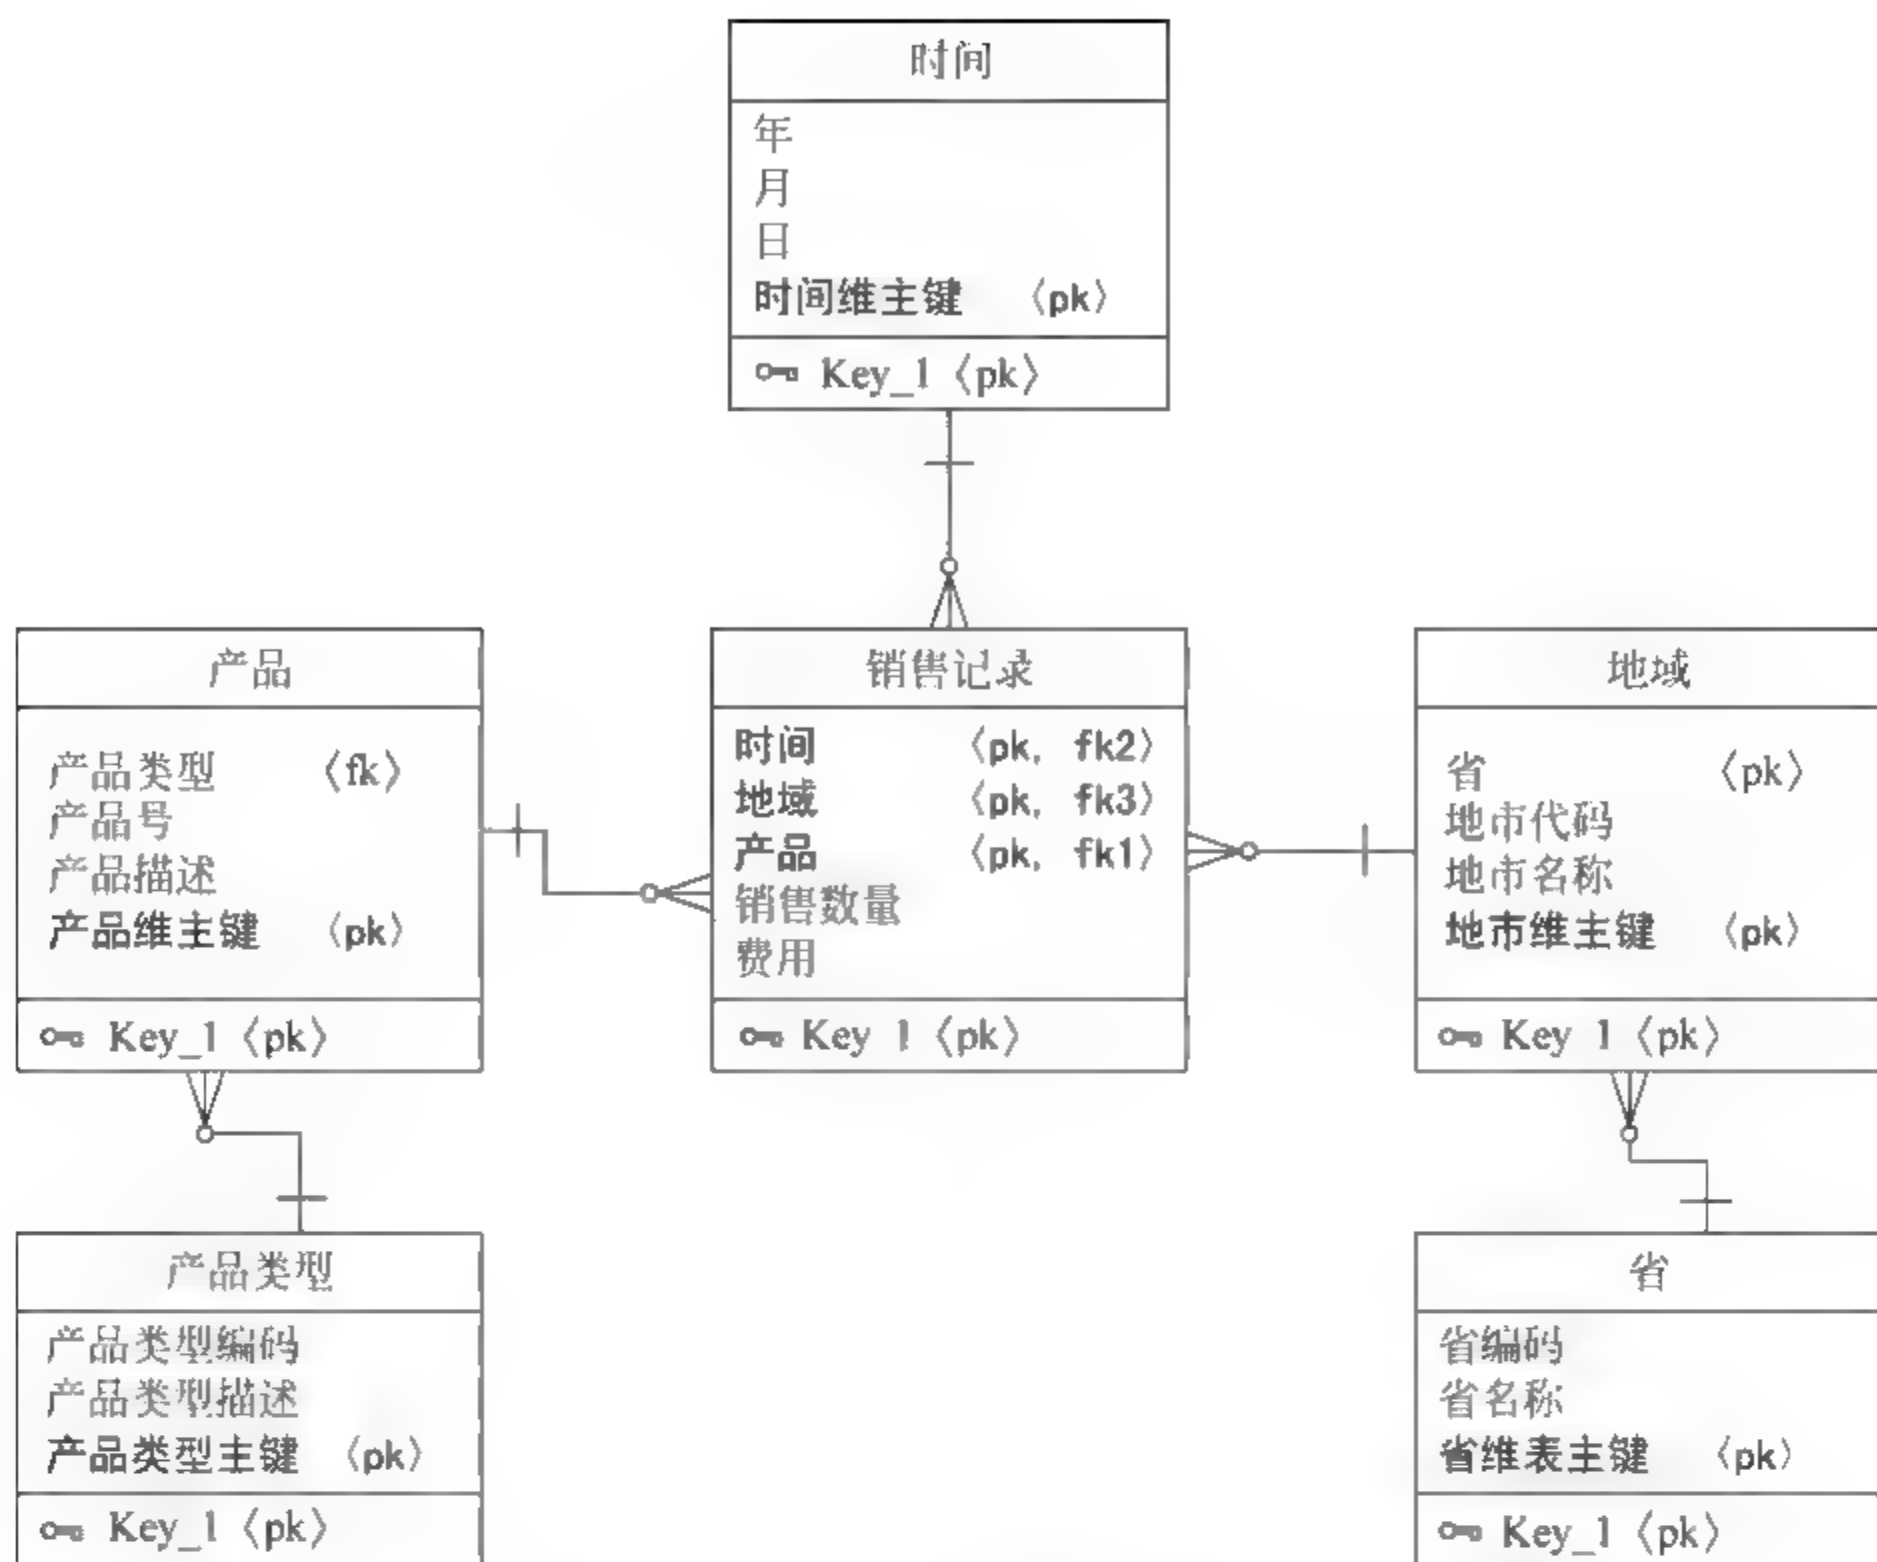


图 2.14 雪花型模式的实例

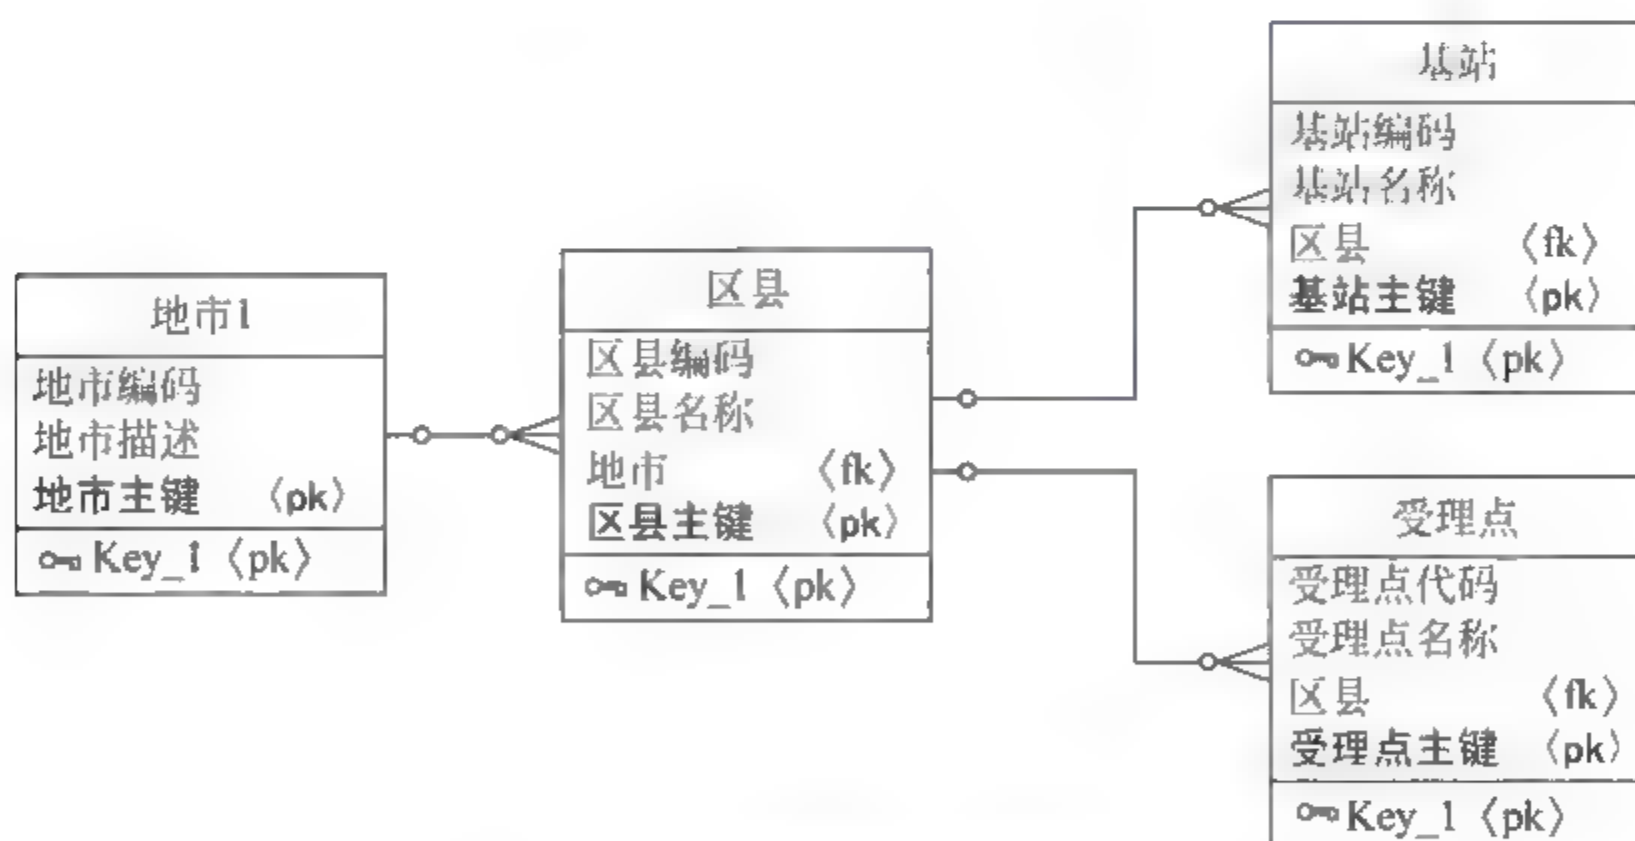


图 2.15 雪花型模式的维表共用

维护工作。但是，查询时使用雪花型模式要比星型模式进行更多的关联操作，反而降低了查询效率。

② 雪花型模式中有些维表并不直接和事实表关联，而是与其他维表关联，特别是对于派生维和实体属性对应的维而言，这样就减少了事实表中的一条记录。因此对于维度较多特别是派生维和实体属性较多的情况下，雪花型模式较为适合。但是当按派生维和实体属性维进行查询时，首先进行维表之间的关联，然后再与事实表关联，因此查询效率低于星型

模式。

③ 使用雪花型模式可以实现维表和事实表之间多对多的关系,例如在如图 2.14 所示的实例中加入销售人员维度,如果一次销售可由多名员工完成,采用雪花型模式实现如图 2.16 所示。

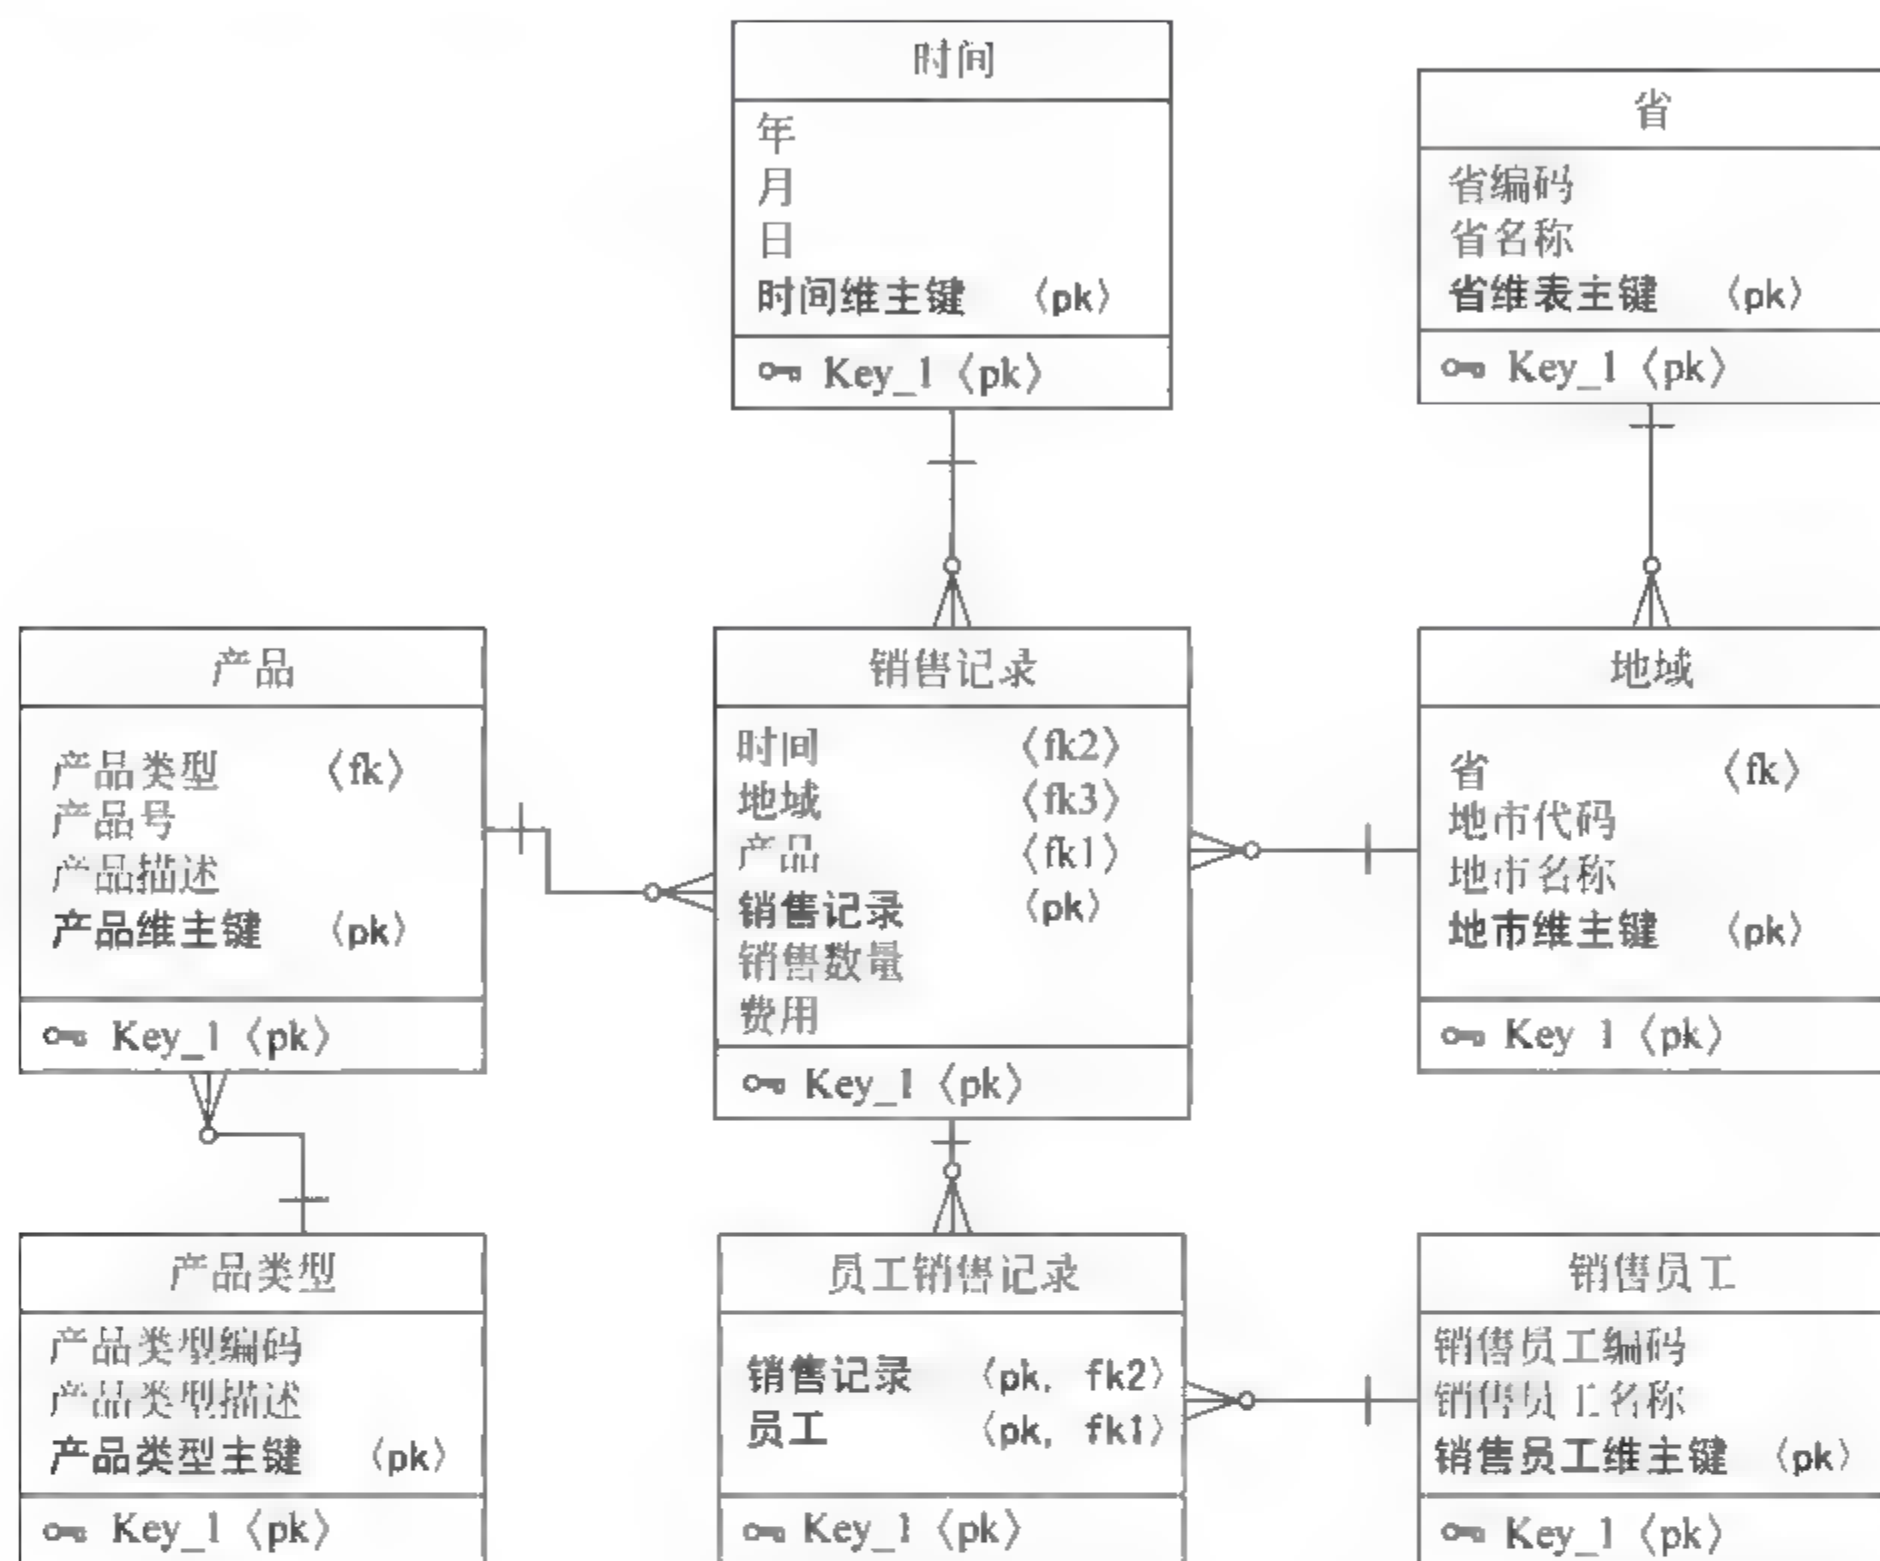


图 2.16 雪花型模式实现多对多关系

综上所述,星型模式结构简单,查询效率高。而雪花型模式通过维表的规范化,增加了维表的共用性。实际应用中,经常将星型和雪花型模式综合起来,即使用星型模式的同时将其中的部分维表规范化,提取一些公共的维表,这样既保证较高的查询效率,又简化维表的维护。

### (3) 星型-雪花型

星型-雪花型模式是星型和雪花型模式的结合,打破星型模式只有一个事实表的限制,且这些事实表共享全部或部分维表,如图 2.17 所示。




图 2.17 星型-雪花型模式示意图



### 3. 物理模型设计

数据仓库的物理模型设计是指在逻辑模型的基础上,使用 DBMS 提供的功能对逻辑模型进行物理上的优化,即根据数据仓库的特点和性能要求,将逻辑模型转化为数据在物理设备上的存储结构与存取方法的过程,如表结构、索引、数据约束、数据类型和数据格式设计等,由项目经理和数据仓库架构师共同完成。

物理模型设计主要包括:

#### 1) 数据存储结构设计

数据存储结构设计主要包括数据文件存储设计、数据文件存储分配以及数据缓冲大小等,其目标是提高系统的 I/O 能力。

作为数据仓库的基础,DBMS 往往可以向用户提供多种存储结构,每种存储结构各有其独特的实现方式。利用 DBMS 构建数据仓库时,应当统一考虑数据存储时间、存储空间效率、数据维护成本等各方面因素,选用适当的存储结构。

#### 2) 数据索引策略设计

数据索引策略设计是指根据数据的特征,如数据的基数和使用情况选择适当的索引,例如使用 Sybase 数据库时,对低基数的数据可以建立位图(bitmap)索引。

数据仓库中数据存储量十分庞大,远远超过一般的数据库系统。当数据仓库数据的更新频率不高,往往采用定期导入新数据的方法。因此,为了有效提高数据仓库的运行效率,可对常见查询所访问的数据进行分析的基础上,设计较为复杂的索引策略。由于数据仓库的数据具有非易失性,因此尽管索引的设计与建立工作量较大,但易于维护。

#### 3) 软硬件配置

数据仓库与其他业务系统不同,尤其需要对数据容量进行估算,这是由于数据仓库是对以往历史数据的集成,如果设计时不加以考虑,很快会造成灾难性后果。数据仓库的容量估算应该是可预见的,首先确定核心明细数据的存储年限,相关表的平均字段长度值 $\times$ 每年的记录数 $\times$ 每年预计的增长,再加上 20% 的冗余,以及磁盘预留的 20% 的冗余,即可得到数据仓库数据量的估算值。

数据仓库的处理能力不仅与容量有关,还与具体的关系数据库的性能息息相关。如何在 Oracle、SQL Server、Sybase 甚至 MySQL 之间寻找平衡,既要考虑实际预算,也要视实际需求而定。关于硬件的配置,既需要发挥软件的功能,满足实际的处理要求,也要为将来的系统扩展保留一定空间。

#### 4) 数据存储策略设计

由于同一个主题的数据可以存放在不同的介质,为了提高存取效率,设计者常常按照数据的重要程度、粒度、使用频率以及响应时间等要求将数据分别存放在不同的存储设备。

数据存储策略包括表的归并、表的物理分割和表的预联接等。

##### (1) 表的归并

表的归并是指在物理上将用户经常要查询的放在一起,减少数据 I/O 次数,提高查询效率,表的归并是 DBMS 提供的功能。

##### (2) 表的物理分割

表的物理分割是指使用 DBMS 提供的功能,对逻辑模型中的数据进行再次分离。通常,逻辑模型按照一定的业务规则对数据进行分割,而物理模型一般是按照数据的使用情况



对数据进行分割,实际中将数据的逻辑分割和物理分割综合加以应用。例如,在逻辑模型中对话单表按照主叫号码的所属地域进行分表设计,在物理模型中对每个表再按照通话日期进一步分区。

### (3) 表的预联接

表的预联接是指根据数据的使用情况,利用 DBMS 提供的功能(例如 Oracle 的实体化视图、Sybase 的联接索引等),对经常关联的表事先进行预联接处理,以提高数据访问速度。

### (4) 表的物理特性设计

表的物理特性设计是指对表的初始块大小等物理特性的设计,主要参考表中数据量的情况,通过对物理特性的设计提高数据生成效率。

### 5) 存储分配参数

在创建传统数据库的过程中,需要确定数据块大小、缓冲区大小以及缓冲区数据等具体与数据存储分配相关的参数。通常不同的数据库厂商都会根据其产品的应用实例给出推荐的配置参数,供设计人员参考进行初始配置,然后在系统维护过程中根据实际情况(数据的增长速度、用户查询的数据量和频率)进行调整。数据仓库是建立在 DBMS 上的,因此两者在这一点上相同。

## 2.2 ETL 设计

除了数据模型设计外,数据仓库设计还包括数据装载接口设计。数据模型设计即前面提及的数据仓库概念模型设计、逻辑模型设计和物理模型设计;数据装载接口设计是指完成从操作型系统的数据表中抽取、转换、清洗以及将细节数据聚合为不同综合层次的数据,主要包括:

(1) 扫描模块的设计。扫描模块用于对现有业务系统进行有效地扫描,以获取需要追加的数据集合。

(2) 定义数据转换和清洗规则。数据仓库需要从多个不同的数据源中抽取数据,不同数据源的数据具有不一致性,良好的数据转换和清洗规则是数据质量的重要保证。

(3) 数据抽取模块的设计。将需要追加的数据通过格式转换、清洗转换为数据仓库的细节表。

(4) 综合模块的设计。将细节数据聚合成各个综合层次的数据。

数据装载接口设计的重点是 ETL 设计,下面将详细进行介绍。

目前,数据仓库接口的实现方法有两种,一是程序员手动设计处理集成的接口程序,即通过代码实现 ETL 过程;二是购买 ETL 工具软件。

如果将数据仓库中数据模型设计比喻为一座大厦的设计蓝图,数据是砖瓦,则 ETL 就是建设大厦的过程。在整个数据仓库的实施过程中,用户需求分析和模型设计是最难的,而 ETL 的设计和实施则是工作量最大的,约占整个项目的 60%~80%,这是国内外众多实践的普遍共识。

### 1. 主要任务

#### 1) 数据抽取

这一部分需要在调研阶段做大量的工作,首先需要了解数据来自哪些业务系统,各个业



务系统的数据库服务器运行哪种 DBMS, 是否存在手工数据, 手工数据量多大, 是否存在非结构化的数据等等, 当收集完这些信息后才可以进行数据抽取的设计。

#### (1) 对于与 DW 数据库系统相同的数据源的处理方法

对于这一类数据源, 设计上比较容易。一般情况下, DBMS 都提供数据库链接功能, 在 DW 服务器和原业务系统之间建立直接的链接关系则可以通过编写 SQL 语句直接访问。

#### (2) 对于与 DW 数据库系统不同的数据源的处理方法

对于这一类数据源, 一般情况下可以通过 ODBC 的方式建立数据库链接, 如 SQL Server 和 Oracle 之间。如果不能建立数据库链接, 可以通过两种方式完成, 一是利用工具将源数据导出到 .txt 或 .xls 文件, 然后再将这些源系统文件导入 ODS; 二是通过程序接口完成。

#### (3) 对于文件类型数据源(如 .txt、.xls)的处理方法

可以培训业务人员利用数据库工具将这类数据导入到指定的数据库, 然后从指定的数据库中抽取。或者借助工具实现, 如 SQL Server 的 SSIS 服务的平面数据源和平面目标等组件导入 ODS。

#### (4) 增量更新的问题

对于数据量庞大的系统, 必须考虑增量抽取情况下, 业务系统记录业务发生的时间作为增量标志, 即每次抽取前首先判断 ODS 中记录的最大时间, 然后根据这一时间去业务系统抽取晚于这一时间的所有记录。一般情况下, 业务系统没有或部分有时间戳。

### 2) 数据清洗

数据清洗(data cleansing, data cleaning, data scrubbing)是一个减少错误和不一致性, 解决对象识别的过程。一般情况下, 数据仓库分为 ODS 和 DW 两部分。通常是从业务系统到 ODS 需要进行清洗, 即过滤脏数据和不完整数据; 再从 ODS 到 DW 需要进行转换, 即进行一些业务规则的计算和聚合。数据清洗的任务是过滤掉不符合要求的数据, 将过滤的结果交给业务主管部门, 确认是否直接过滤还是由业务部门修正后再进行抽取。数据清洗的目的是保证数据仓库的数据质量。

数据质量定义为数据的一致性(consistency)、正确性(correctness)、完整性(completeness)和最小性(minimality)四个指标在系统中得到满足的程度。其中:

- 一致性 数据的值和描述在全局即数据仓库中均表示同样的含义。
- 正确性 数据的值和描述一定是真实的和业务系统保持一致的。
- 完整性 确保所有数据都必须是有意义的(不能为空值)。
- 最小性 数据的值和描述有且仅有一个含义。

根据处理的是单数据源还是多数据源以及是模式层的还是实例层的, 可将数据质量问题划分为四类: 单数据源模式层问题(如缺少完整性约束、糟糕的模式设计等)、单数据源实例层问题(如数据输入错误)、多数据源模式层问题(如异构数据模型和模式设计等)、多数据源实例层问题(如冗余、冲突和不一致的数据等)。单数据源中出现的问题在多数据源中也可能出现, 并且这种现象很普遍; 模式层的问题也会体现在实例层上。模式层的问题可以通过改进模式设计、模式转化和模式集成加以解决; 但实例层的问题在模式层上是不可见的, 所以数据清洗主要针对实例层的数据质量问题。



实际上,数据清洗是利用诸如数理统计、数据挖掘或预定义的数据清洗规则等将脏数据转化为满足数据质量要求的数据。

按照数据清洗的实现方式和范围,可将数据清洗划分为四种类型,即:

- (1) 手工实现方式:用人工检测所有的错误并改正,只适用于小数据量的数据源。
- (2) 通过编写专门的应用程序:通过编写程序检测/改正错误。但通常数据清洗是一个反复的过程,将导致清理程序复杂、工作量大。
- (3) 某类特定应用领域的,如运用概率统计方法查找数值异常的记录。
- (4) 与特定应用领域无关的,主要集中于重复记录的检测/删除。

数据清洗是 ETL 的一个重要环节,其主要任务是检测并删除/改正将装载到数据仓库的脏数据。由于数据仓库的多种异构数据源和海量数据,数据清洗应是与领域无关的,而且数据清洗不是 ETL 中一个独立的步骤,需要与数据抽取、转换/集成和装载协同配合,并循环反复进行。如果数据源是一个功能较强的 DBMS(如图 2.18 中的数据源 1 和数据源 2),则可以在数据抽取时使用 SQL 完成一部分的数据清洗工作,但是有一些数据源不提供这种功能(如图 2.18 中的数据源 3),只能直接将数据从数据源抽取出来,然后在数据转换时进行清洗。数据仓库的数据清洗主要还是在数据转换时进行的,使用 DBMS 的转换清洗功能完成大部分的工作,这样数据清洗就充分利用了 DBMS 提供的功能。

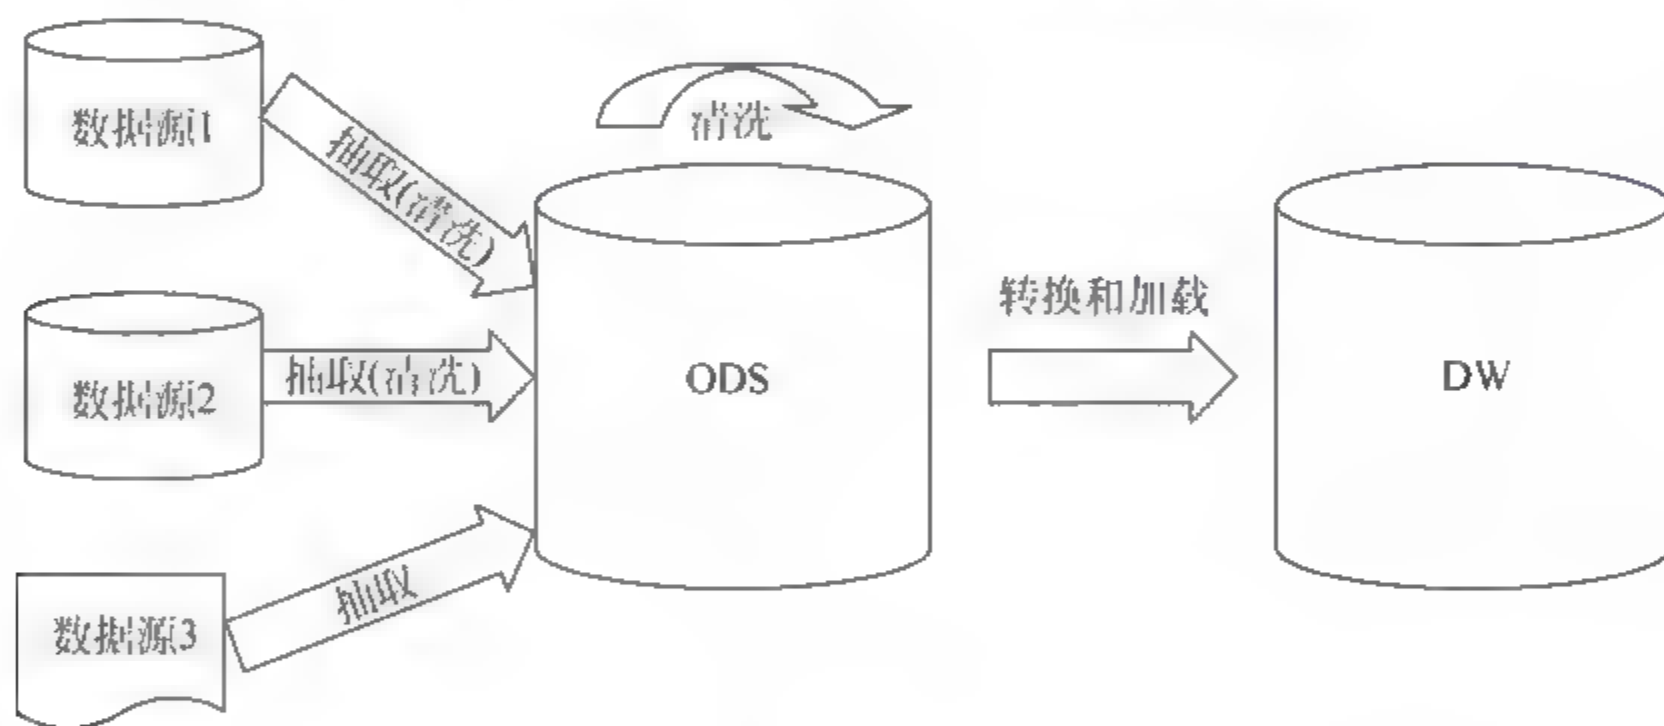


图 2.18 数据清洗过程

数据清洗是一个反复的过程,不可能在几天内完成,只有不断地发现问题、解决问题。对于是否过滤,是否修正往往需要用户确认。对于过滤掉的数据,写入 Excel 文件或将过滤数据写入数据表,在初始阶段可以每天向业务部门发送过滤数据的邮件,促使尽快修正错误,同时也可以作为将来验证数据的依据。

### 3) 数据转换

数据仓库抽取数据的过程是从业务数据库开始的,中间会经过数据转换的过程,成为数据仓库需要的数据。在进行数据转换之前,必须首先进行数据映射(source data mapping),明确定义数据仓库的每个表、每个字段来自源系统或接口单元中的哪个表、哪个字段。这种映射关系可能很简单,例如表是完全一对一的关系,直接复制到数据仓库即可;也可能很复杂,数据仓库的某张表可能来源于源系统中的多个表,这些源表通过一定的关系被关联起来,然后对表中的一些字段进行转换后,变成数据仓库中目标表的对应字段。数据转换的任务是对不一致数据的转换、数据粒度的转换以及一些业务规则的计算。其中:



(1) 不一致数据的转换：这是一个整合的过程,将不同业务系统相同类型的数据统一。例如同一个代理商在结算系统的编码是 XX0001,而在客户关系管理(Customer Relationship Management,CRM)系统的编码是 YY0001,这样在抽取后统一转换成同一个编码。

(2) 数据粒度的转换：业务系统一般存储非常明细的数据,而数据仓库的数据用于分析,不需要非常明细的数据。一般情况下,会将业务系统的数据按照数据仓库的粒度进行聚合。

(3) 业务规则的计算：不同的企业拥有不同的业务规则、不同的数据指标,这些指标有时不是简单的运算能够完成,需要在 ETL 中将这些指标进行计算后存储在数据仓库,供分析使用。

#### 4) 数据装载

数据装载是将从数据源抽取、转换、清洗后的数据装载到数据仓库。数据装载策略需考虑装载周期以及数据追加策略两个方面。根据业务数据的实际情况,装载周期应综合考虑业务分析需求和系统装载代价,对不同业务系统的数据采用不同的装载周期,但必须保持同一时间业务数据的完整性。数据追加策略根据数据抽取策略以及业务规则确定,一般分为直接追加、全部覆盖和更新追加三种类型。

(1) 直接追加是指每次装载时直接将数据追加到目标表。

(2) 全部覆盖是指如果抽取数据本身已经包括数据的当前和所有历史状况,可对目标表采用全部覆盖的方式。

(3) 更新追加是指对于需要连续记录业务的状态变化,并用当前最新状态与历史状态进行对比的情况,可以采用更新追加的方式。

## 2. 设计原则

由于数据源的多样性,数据传输条件的不确定性以及用户对最终统计数据的选择性等因素,使得 ETL 设计不仅要考虑业务数据处理的要求,还应考虑数据传输过程中如何解决上述问题。ETL 设计一定是针对具体应用,不同的业务和分析模型的抽取要求不同,所以 ETL 整体架构的灵活性和扩展性非常重要。

ETL 设计应遵循的原则如下：

(1) ETL 设计前需要根据业务特点确定分析主题和分析模型的结构,区分维度数据和事实数据,建立相应的数据仓库模型。在设计过程中应考虑是否需要预留字段,增加属性等。

(2) 数据粒度在同一立方体(Cube)中必须统一。事实表的粒度就是维表与事实表关联的最小级别,尽可能采用粗粒度以有效减少数据量,但是不同的分析可能存在差异,例如话务量趋势预测的主题中可以小时为粒度,但是在一些实时性要求较高的忙时话务量分析主题中需要采用 15 分钟甚至 5 分钟的粒度。

(3) 数据周期的确定,在 ETL 设计时需要事先确定抽取的时间,这可能需根据用户对实时性的要求作为调整的依据。

(4) 尽量采用增量的抽取方式以减小每次抽取的数据量。

(5) 数据流和工作流的概念。在 ETL 中需要考虑数据在每一步骤的状态和转换行为,数据的清洗、转换和加载过程是由很多步骤完成的,每一步骤一定是数据的一个原子业务操



作。可以根据需要调整步骤,在数据流可能会出现分支的情况,即在不同条件下采用不同的处理逻辑。

(6) 流程的异常处理。在流程中需要考虑各种可能的异常的存在,如网络闪断,数据的延迟产生等等。因此,需要在流程中加入一些补救措施予以纠正,保证导入数据仓库的数据绝对正确(但流程的设计尽量依照简单、高效的原则)。

(7) ETL 的调整、运行管理以及监控。ETL 程序的运行应该有相关的管理和监控工具。一方面用于 ETL 的设置和调整;另一方面也便于 ETL 出现异常时能够及时通过人工方式干预,保证 ETL 正常运行。

(8) 针对业务需求进行 ETL 的配置和设置,方便专业维护人员和开发人员对抽取任务进行调整和灵活配置。

(9) Cube 的管理。除了对数据仓库的管理和数据的处理之外,ETL 很重要的工作是对 Cube 的管理。根据 Cube 特性考虑对维度和 Cube 的更新,以及对 Cube 分区的新建、处理和合并等一系列操作。

(10) 数据仓库有一个初始化的过程,即将以前的业务数据进行整理和加载,但是数据量非常巨大,需要花费较长的时间,而且抽取策略与平时的不同。

(11) 程序具有自修复功能。在任何一个步骤出现异常,ETL 程序都能够回退到抽取前的状态,而不需要人工干预,更不能影响到已抽取的数据。

### 3. 设计步骤

ETL 设计的主要步骤如下:

#### 1) 设计数据准备区的数据结构

数据准备区是 ETL 专门用于对数据进行抽取、清洗和转换等处理的临时数据库,需要根据实际需求设计数据准备区的库表结构。

#### 2) 定义数据抽取规则

数据抽取首先需要定义数据抽取规则,记录在“数据抽取规则表”中,然后再设计数据抽取流程。

#### 3) 定义数据清洗规则

数据清洗转换是为了处理数据源中存在错误、不一致或无用的数据,即“脏数据”。在清洗“脏数据”之前,必须清楚存在哪些“脏数据”,并记录在“脏数据登记表”中。对发现的“脏数据”,逐一确定清洗转换规则,记录在“清洗转换规则表”中。

#### 4) 定义数据转换规则

数据转换是将抽取的数据进行过滤、合并、解码和翻译等,为数据仓库创建有效数据的过程。转换的过程需要理解业务侧重点、信息需求和目前可用的源数据。通常数据抽取完毕后,应根据企业业务的具体需求,设计和定义一系列的数据转换规则,转换规则主要包括:

(1) 字段级:定义数据类型转换、增加“上下文”数据,如时间戳。

(2) 多数据源整合:字段映射(mapping)、代码变换(transposing)将不同数据源中的数据值规范成数据仓库的数据值。例如,将源系统非英文编码转换成数据仓库英文编码,将源系统信息编码转换成数据仓库信息编码等。合并(merging)将两个或更多源系统记录合并成一个输出或目标记录。派生(derivation)根据源数据,利用公式产生数据仓库需要的数据。例如由身份证号码计算生日、性别和年龄等。



(3) 聚合(aggregation)和汇总(summarization)

#### 5) ETL 流程设计

ETL 流程设计是定义 ETL 流程的步骤,并确定每一步骤需要完成的工作,以流程图的形式加以描述。

#### 4. 实现工具

一个有效的 ETL 方案是成功构建数据仓库的首要因素。ETL 实现方式有两种,即购买 ETL 工具和手工编码,表 2.2 给出了这两种方式的比较,为企业最终根据实际情况选择合适的方式提供参考,ETL 工具早期的数据迁移大多是开发人员手工编码实现。

表 2.2 购买工具和手工编码两种 ETL 实现方式的比较

性 能	ETL 工 具	手 工 编 码
灵活性	比较灵活	非常灵活
难易程度	相对容易	要求一定技术水平
管理和维护	容易	较难
性能和效率	较高	取决于代码的质量
开发周期	较短	较长
工作量	中等	较重
价格	较高	相对较低

选择 ETL 工具时应考虑可能影响 ETL 功能的主要因素,主要包括平台的支持;数据转换功能;管理和调度的功能;集成和开发性以及元数据的管理等。目前,市场上主流的 ETL 工具分为两大类:一类是 ETL 厂商提供的产品,一般都具有较完善的体系结构和功能,典型产品包括 Ascential DataStageXE 和 Informatica;另一类是数据库厂商提供的整体数据仓库解决方案和产品,这类产品在提供数据仓库存储、设计和展现工具的同时提供相应的 ETL 工具,它们对相关产品具有很好的支持并能发挥出最大效率,但结构封闭,对其他厂商的产品支持有限,如 Oracle Warehouse Builder 和 IBM Warehouse Manager 等。

评价 ETL 工具的主要因素包括:

- 可靠性:系统具有高的容错性和故障恢复能力,具备完善的备份、恢复等机制保证系统的稳定性和可用性。
- 可衡量性:系统的性能指标可以根据系统的软硬件配置进行调整,系统扩展性强。
- 性能:系统具备并行计算、负载调度等保障系统性能的良好机制和能力。
- 代码生成能力:将图形化操作生成的 ETL 过程转换为标准 SQL 或系统专用存储过程的能力。
- 开发:系统提供的开发接口的通用性、灵活性、功能性决定了系统开发的工作量和难度。
- 元数据管理:系统可以维护 ETL 中的技术元数据和业务元数据。
- 管理:ETL 的管理包括系统的安装、配置以及维护。

四种常用 ETL 工具的综合比较如表 2.3 所示。

表 2.3 四种常用 ETL 工具的综合比较

工具名称	可靠性	可衡量性	性能	代码生成能力	开发	元数据管理	管理
Power Mart	B	B	A	A	A	B	A
Datastage	B	B	A	A	A	B	A
OWB	B	B	C	B	B	C	B
DB2 WM	B	A	C	B	B	C	B

注：A 表示优秀,B 表示较好,C 表示一般。

2.3 数据仓库实现

数据仓库实现的方法主要包括自顶向下、自底向上、平行开发、有反馈的自顶向下和有反馈的自底向上等,这里主要介绍当前业界流行的自顶向下、自底向上和平行开发三种。

1. 自顶向下

这是一种由整体到局部,逐步细化的实现方法。首先对分散在各业务数据库的数据特征进行分析,在此基础上实施数据仓库的总体设计和规划,准备元数据。随后,进行外部数据源的数据抽取、转换和加载等一系列处理,并将处理后的数据导入数据仓库,元数据也同时导入,从而建立一个完整的数据仓库,并针对各个主题建立数据集市,以满足分析决策的需求,如图 2.19 所示,其中数据集市是数据仓库的真子集。数据仓库的实现过程直观、清晰、易于理解,只要对外部数据源和所支持的决策有较深入的理解,保证各数据集市都是数据仓库的真子集,则可以完全消除信息之间的“珠网”现象。




图 2.19 自顶向下的数据仓库实现方法

其不足之处是要求设计者对业务有深入的理解,系统设计规模偏大,实施周期过长,见效缓慢,尤其在项目实施初期见效不明显。

2. 自底向上

一般企业在构建数据仓库时,往往准备的数据规模偏小,决策目标不明确,并且希望数据仓库能较快地发挥作用,产生效益。为了满足上述要求,并克服自顶向下方法的不足,自底向上的方法应运而生。

与自顶向下方法相反,自底向上方法的设计思路是先具体,后综合。首先,将企业内部各部门的需求视为分解后的决策子目标,并针对这些子目标建立各自的数据集市,从而获得最快的回报。在此基础上,对系统不断扩充,逐步形成完善的数据仓库,以实现对企业决策的支持。由于数据集市结构简单,数据综合度较低,因此不需要创建数据仓库所必需的元数据部件。自底向上的实现方法如图 2.20 所示。其特点是投资小、见效快。由于部门级的数据结构简单,决策需求明确,因此易于实现。但是由于数据集市缺少元数据,最终构建数据仓库的过程具有相当的难度,并有可能影响数据仓库整体结构的合理性以及系统运行的效率。



### 3. 平行开发

平行开发是指在同一个模型的指导下,建立数据仓库的同时,建立若干个数据集市,如图 2.21 所示。这种方法是在自顶向下的基础上,同时吸收了自底向上的优点,因此可以认为是两种方法的有机结合。




图 2.20 自底向上的数据仓库实现方法

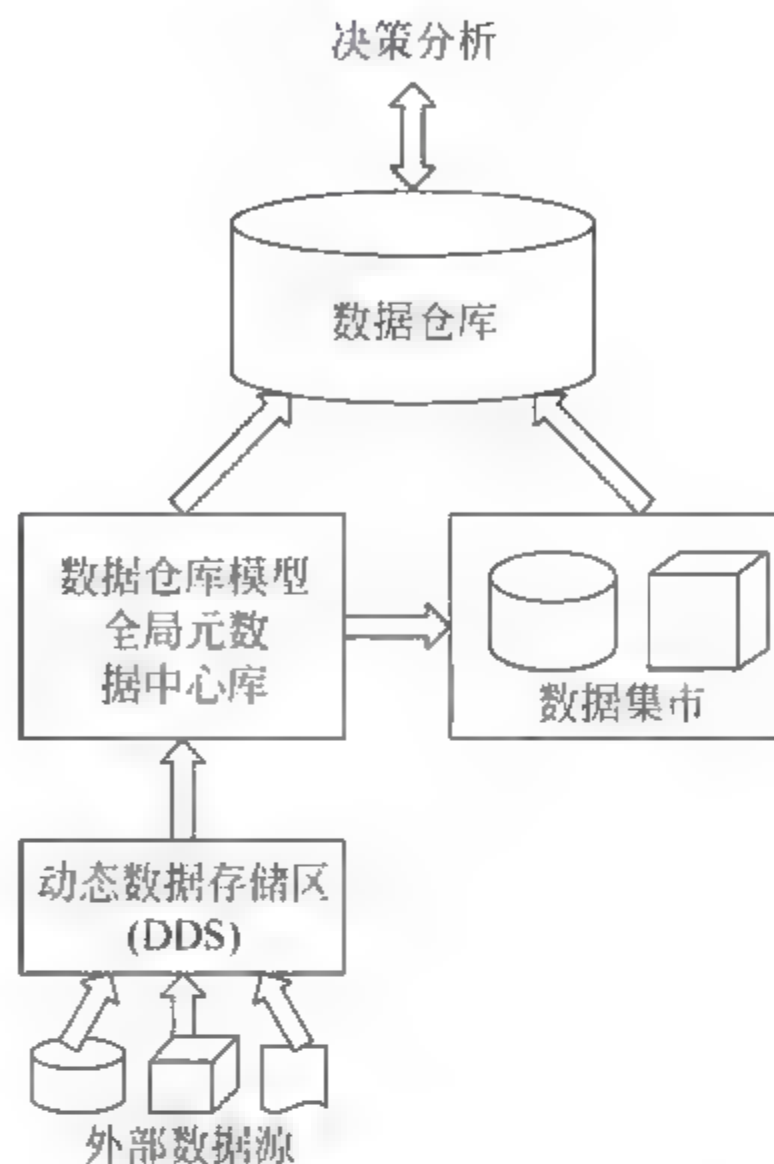


图 2.21 平行开发的数据仓库实现方法

平行开发中,数据仓库和数据集市遵循统一数据模型的指导,同时建立,避免建立相互独立的数据集市的盲目性,有效减少数据的不一致和冗余。其核心为两部分:一是统一的全局元数据中心库(GMR),记录数据仓库的主题域、通用维、业务规则和其他各种元数据;其二是动态数据存储区(DDS),存储从外部数据源抽取的数据,并为进一步处理做好准备。GMR 和 DDS 不是一成不变的,它们都随着外部数据源以及决策需求的变化而改变。

上述实现方法中,第一种方法类似于软件工程中“自顶向下”的方法,投资大、周期长。第二种方法恰好相反,类似于软件工程中“自底向上”的方法,投资少、周期短且易见成效,但由于设计之初是以特定的部门级主题为框架,向其他的主题和部门扩充往往比较困难。实际中,大多采用第二种方法。

“自底向上”地建立数据仓库,并不意味着不需要在设计阶段的长远规划。采用逐步积累的方式建立数据仓库,其最大的问题是已有的框架无法把新的业务集成进来。因此,在设计阶段就必须充分考虑到这一点。例如,部门级的主题是否有助于形成企业级的主题,数据加载模块是否能够重用等等。数据仓库的长远规划,并不仅仅是技术部门的事情,应当把构建数据仓库作为企业发展战略的一个组成部分。在设计阶段需要不同部门的沟通和协调,技术框架和系统设计必须从整个企业的角度加以考虑,即使刚开始实施时是面向某个部门的。就这一点而言,建立一个企业级的数据仓库,主要的障碍不是技术,而是不同部门之间的组织和协调问题。

目前,系统开发方法有多种,如生命周期法、快速原型法和螺旋法等。通常人们在开发数据库系统时多采用生命周期法或原型法,但由于数据仓库固有的特点,传统的生命周期法



和原型法并不适用于数据仓库的开发。

螺旋式开发方法采用“分而治之”的思想,将一个庞大的任务划分成多个阶段。在每一阶段,项目按照问题定义、系统分析、系统设计、开发、实现、维护和系统评估进行。一个阶段完成后,再开始新的阶段,而每一阶段都是以前一阶段的结果为参考点,再增加新的需求项目,直到所有的需求都满足为止。

螺旋式开发方法具有以下特点:

- 每一个区域均含有一系列适应待开发项目特点的工作任务。
- 适用于需求不断增长系统的开发。

与传统的开发方法不同,螺旋法不是当软件交付时就结束了,它能够适用于系统开发和使用的整个生命周期,一直运转到软件退役。有时这一过程处于休眠状态,但任何时候出现了改变,过程都会从合适的人口点开始继续运转。

一般地,数据仓库的原始需求并不明确,且不断变化与增加,开发者最初并不能确切了解用户明确而详细的需求,用户所能提供的无非是需求的大方向以及部分需求,不能较准确地预见到以后的需求。因此,数据仓库比较适合采用螺旋式的开发方法,但是这又不同于一般意义上的螺旋法,数据仓库是在原有数据库基础上构建的,即从已经存在于操作型数据库环境中的数据出发构建数据仓库,即是“数据驱动”的,因此恰当的称谓是数据驱动的螺旋式开发方法,该方法将数据驱动的思想与螺旋法结合起来。基于“数据驱动”的主要特点是:

- 利用以前已经建立的数据库构建数据仓库。尽量利用已存在的数据和代码,而不是从头开始,这是数据驱动思想的出发点。
- 基于数据驱动的方法不再面向应用,而是面向主题。数据仓库的开发是从已有的数据库系统出发,按照分析领域的要求对数据及数据之间的关联重新考察,以组织数据仓库的主题。

基于数据驱动的螺旋式开发方法是一个不断向外扩展的迭代过程,其起点较低,每迭代一次,螺旋线增加一周,数据仓库的开发又前进一个层次,系统又生成一个新版本,而软件开发的时间和成本又有新的投入。在沿螺旋线前进的过程中,最后总能得到一个用户满意的软件版本。所以基于数据驱动的螺旋式开发方法,非常适于数据仓库面向主题、基于数据驱动的开发特点。该方法也是目前数据仓库常用的开发方法。

数据仓库的建立是一个数据驱动、技术支撑并满足应用需求的不断增长的开发过程。数据仓库的开发像生物一样具有其特有的、完整的生命周期。数据仓库的开发周期可以分为规划分析阶段、设计实施阶段以及使用维护三个阶段。这三个阶段是一个不断循环、完善和提高的过程。一般情况下,数据仓库不可能在一个循环过程中完成,而是经过多次循环,每次循环都会为系统增加新的功能,使数据仓库的应用得到新的提升。

数据仓库建成后进入运行维护。一方面,用户使用数据仓库中的数据进行决策或者分析,即在数据仓库中建立 DSS 应用,同时,用户将使用情况和新的需求反馈给开发人员以进一步完善系统,并管理数据仓库的一些日常活动,如刷新数据仓库的当前详细数据,将过时的数据转换为历史数据,清除不再使用的数据,并调整数据粒度级别等。

数据仓库维护的首要任务是数据备份与恢复。数据仓库的数据是多年积累的结果,可能包括 10 年甚至 20 年的数据。这些数据代表了企业浓缩和丰富的历史。构建一个成功的



数据仓库投入的资源无疑是巨大的,所以数据仓库的数据一旦丢失,将给企业造成重大损失。为避免这种灾难的发生,需要对数据不断备份。

### (1) 备份

备份是数据安全的保证。实现备份需要考虑以下因素:

- 确定哪些部分需要备份。将当前数据和历史数据分离,当前数据源随操作型系统的输入而增长,历史数据是过去的内容,应经常性地备份当前数据,历史数据没有必要频繁备份。
- 数据仓库的容量是一个大问题。完全备份数据仓库需要花费很长的时间,除了完全备份,可以考虑日志备份和差异备份。
- 定期归档数据。在数据仓库中周期性地将非常陈旧的数据归档。归档可以减少备份和恢复的时间,提高检索性能。
- 备份时间。OLTP 系统备份一般在晚上执行,但对于数据仓库晚上的时间用于每日的增量装载,可以考虑备份和装载同步进行。如果可用的话,将增量装载文件作为备份的一部分存储。
- 备份介质的选择。备份介质的选择很重要,这取决于数据仓库的容量。

### (2) 恢复

当数据仓库发生崩溃时,可以利用备份文件恢复系统。一般地,恢复过程需要注意以下问题:

- 明确的恢复计划。将不同的灾难情况列表,指出每种情况下如何恢复。
- 考虑公司的条件,建立恢复步骤,估计恢复的期望停机时间,正确、迅速地通知用户。
- 如果必须在源系统完成恢复过程,应保证源系统可用。

构建数据仓库是一项长期工作,与其他系统一样需要在运行过程中不断调整和完善。其次是性能优化。数据仓库涉及海量数据的查询和大量写入读出,不仅对系统要求很高,而且与 OLTP 的要求极为不同,因此在数据仓库设计、开发、实施和维护过程中,数据仓库系统的性能都是一个不容忽视的问题。尤其是在运行期间,应密切关注应用对系统资源的消耗情况,针对应用特点及时进行系统的调整,包括调整数据库参数、数据分片设置、创建特殊索引乃至提高系统配置等。

此外,还可以考虑模型的调整。应用与需求是相互促进、不断发展的,随着系统建成并运行,用户在对系统了解不断加深的过程中,也会对系统提出更新、更高的要求。如何在最小投入的前提下满足用户的需求,也是一个值得注意和潜心研究的问题。应尽可能挖掘现有系统的潜力,其次考虑对主题的增加或在现有系统增加少量指标,对系统进行适当调整,最后才考虑系统重构,尽可能减小系统建设的投入。

# 第 3 章 数据仓库实例

## 3.1 实例一

随着数据仓库技术的成熟,国外数据仓库技术已广泛应用于电信、金融和保险等行业。近年来,中国移动、中国电信和中国联通等电信运营商纷纷制定出经营信息服务系统技术规范和业务规范,开始建设企业级数据仓库系统,引领国内数据仓库应用的发展。

在“全业务”运营模式下如何发挥综合优势,实现灵活多变的市场营销策略,为客户提供更具有针对性的服务;同时最大限度地合理配置和优化自身资源,降低运营成本,以增强企业的核心竞争力,成为当前迫切需要解决的问题。其中,市场策略的应对速度是保持竞争力的重要手段,而市场应对策略的制定需要丰富、真实、及时的经营信息提供支持。因此,构建数据仓库势在必行。下面将详细介绍如何构建一个简单的面向电信领域的数据仓库。

### 3.1.1 选择主题

根据电信业务和运营的需求,其主要主题域如图 3.1 所示。

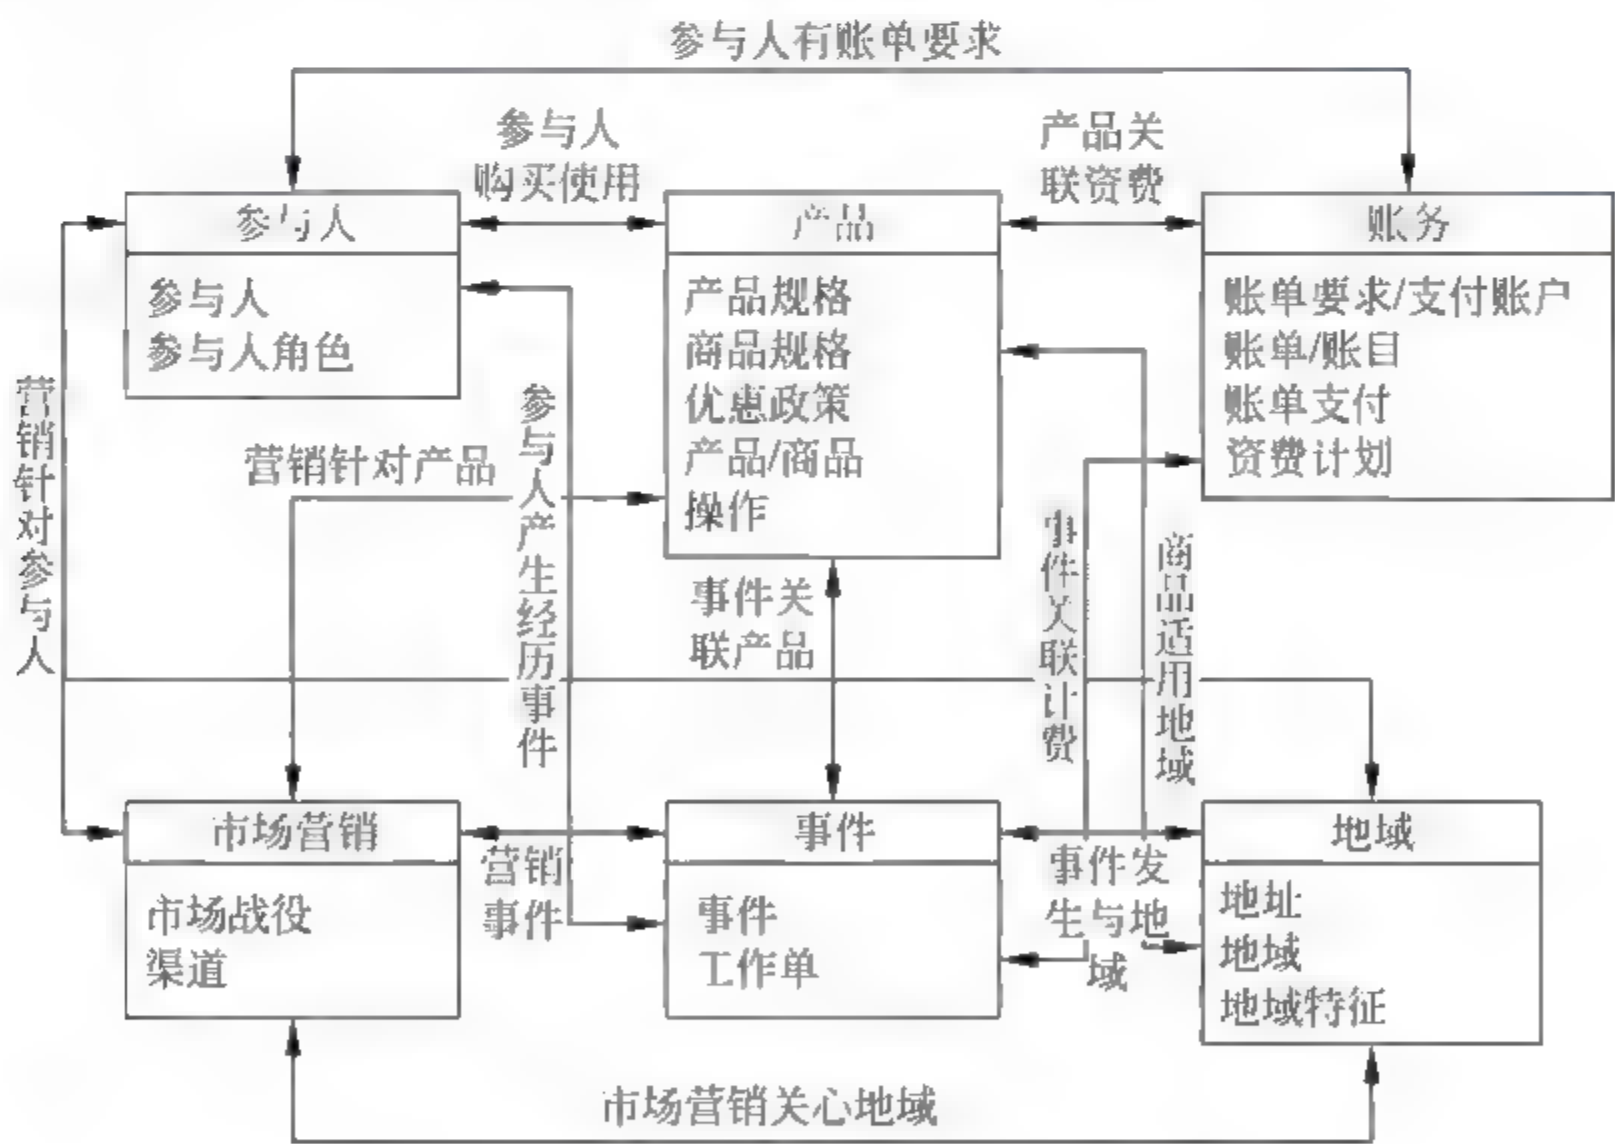


图 3.1 电信领域的主要主题域

- (1) 参与人主题域指与电信运营商的业务或管理活动存在联系的任何个人或组织机构,是一切电信活动的主体,包含电信企业的客户、联系人等所有消费电信产品的信息,参与人角色则描述了参与人在消费过程中扮演的角色。
- (2) 产品主题域主要包括产品和商品两个概念。产品是指电信运营商利用自身的资源



或者第三方资源,为客户提供具有市场价值的基本元素;商品是指电信运营商利用营销手段针对不同的营销渠道、客户细分、地域细分和销售目标等,对产品规格、资费计划进行必要的组合包装的产物。产品是电信企业提供的基本服务单元,如固定电话、小灵通、专线等;商品是指给产品制定了资费以后的服务。参与人直接购买使用商品。

(3) 账务主题域是指参与人使用商品过程中所产生的费用、账目等,这些账目的资费是根据商品的资费进行计算的。

(4) 市场营销主题域主要包括市场战役和渠道。市场战役主要描述企业在市场营销活动中的策略和效果;渠道是企业利用营销的管理手段管理企业客户的方法。

(5) 事件主题域给用户提供了一个客户生命周期的完整视图,记录客户与电信运营商关系的不同阶段。

(6) 地域主题域是指在地理上能被确定的一块地方,是一个面的概念,可以是行政区域也可以是电信的管理区域。

通常情况下,根据需求选择用户最关心的主题域,同时还要兼顾业务系统的数据提供能力。

### 3.1.2 逻辑模型设计

本例中,逻辑模型设计主要包括以下几个方面。

#### 1. 选择数据源

构建面向电信领域的数据库,数据源主要是来自于各类业务以及营业、账务、计费等生产系统的数据,如客户资料、通话详单和出账数据等。

下面分别给出了移动业务的客户资料表、客户出账表和通话详单表的常用字段。

(1) 客户资料表的常用字段包括:

- 客户标识;
- 手机号码;
- 客户类别;
- 客户姓名;
- 证件类型;
- 客户证件号码;
- 归属局;
- 付费方式;
- 入网日期。

(2) 出账表的常用字段包括:

- 客户标识;
- 基本月租费;
- 增值服务费;
- 本地通话费;
- 长途通话费;
- 国内漫游通话费;

- 国际漫游通话费；
- 短信费；
- 总费用。

(3) 通话详单表的常见字段包括：

- 呼叫类型；
- IMSI 号；
- 主叫号码；
- 被叫号码；
- 通话开始时间；
- 通话时长；
- 通话位置；
- 漫游类型。

2. 确定数据粒度

数据仓库设计中最重要步骤之一是确定数据粒度。

1) 选择数据粒度

由于电信运营商业务系统的数据量很大，例如某省一天的 GSM 业务详单数据量就达 1.2GB 左右，客户账单的数据量每个月也有 2000 多万条，同时对详单数据保留周期要求在线保存 3 个月，其他如客户资料、账单和欠费等详细数据的保留周期更长，因此数据仓库系统应采用多重粒度，使数据在当前细节级和各个汇总级都存在，以满足用户的不同查询需求。

对于客户资料，由于是属于增长较为缓慢的信息（随着客户数量的增长，客户业务信息的变更表会增长），可以使用单一数据粒度。如果客户数量很大，每个月生成一张客户资料表将浪费大量的空间，因为只有客户资料变化或新增客户，才需要修改原先的客户资料表，采用增加一个“当前标志”字段，标识客户的当前信息，并选择“数据变更日期”作为时间字段，如图 3.2 所示。

对于客户出账信息，每月每个客户标识只在账务信息中对应一条记录，本身就具有一定的综合性，可以采用单一数据粒度，如图 3.3 所示。

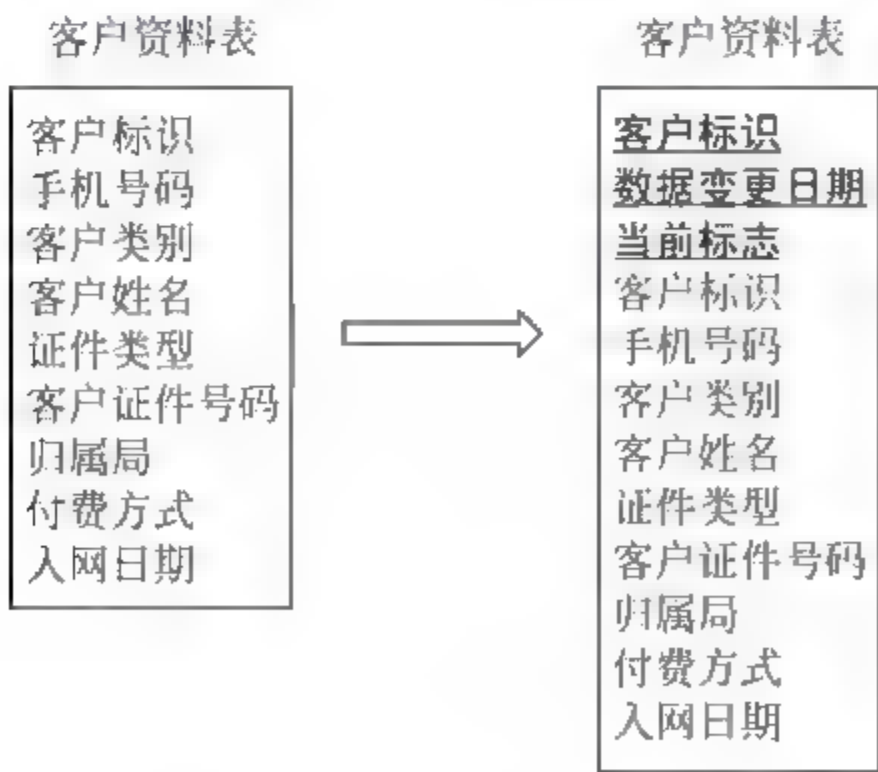


图 3.2 使用单一粒度的客户资料

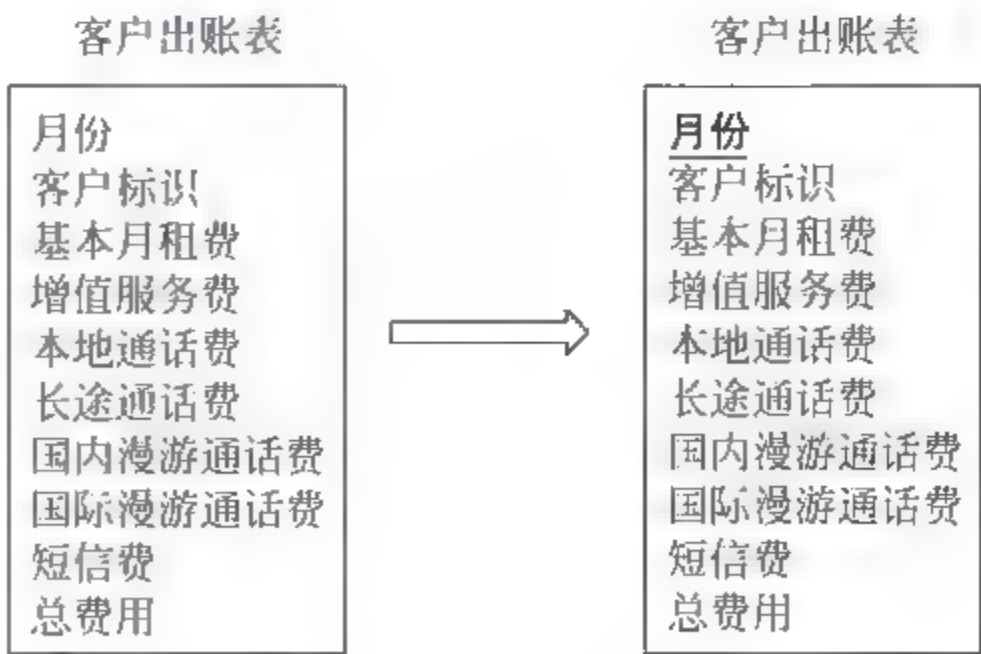


图 3.3 使用单一粒度的客户出账数据



通话详单数据量最大,对于一个客户的一次通话(无论是主叫或被叫,因为一次通话实际上将生成主叫、被叫两条记录),通话详单中将出现一条通话记录,因此对于一个大型的电信公司,其通话详单数据量非常大,所以采用双重粒度。

最近3~4个月的通话详单数据,保留在数据仓库中,并定期聚合成按月综合,然后将细节数据导出,为另外保存新的细节数据腾出空间,如图3.4所示。

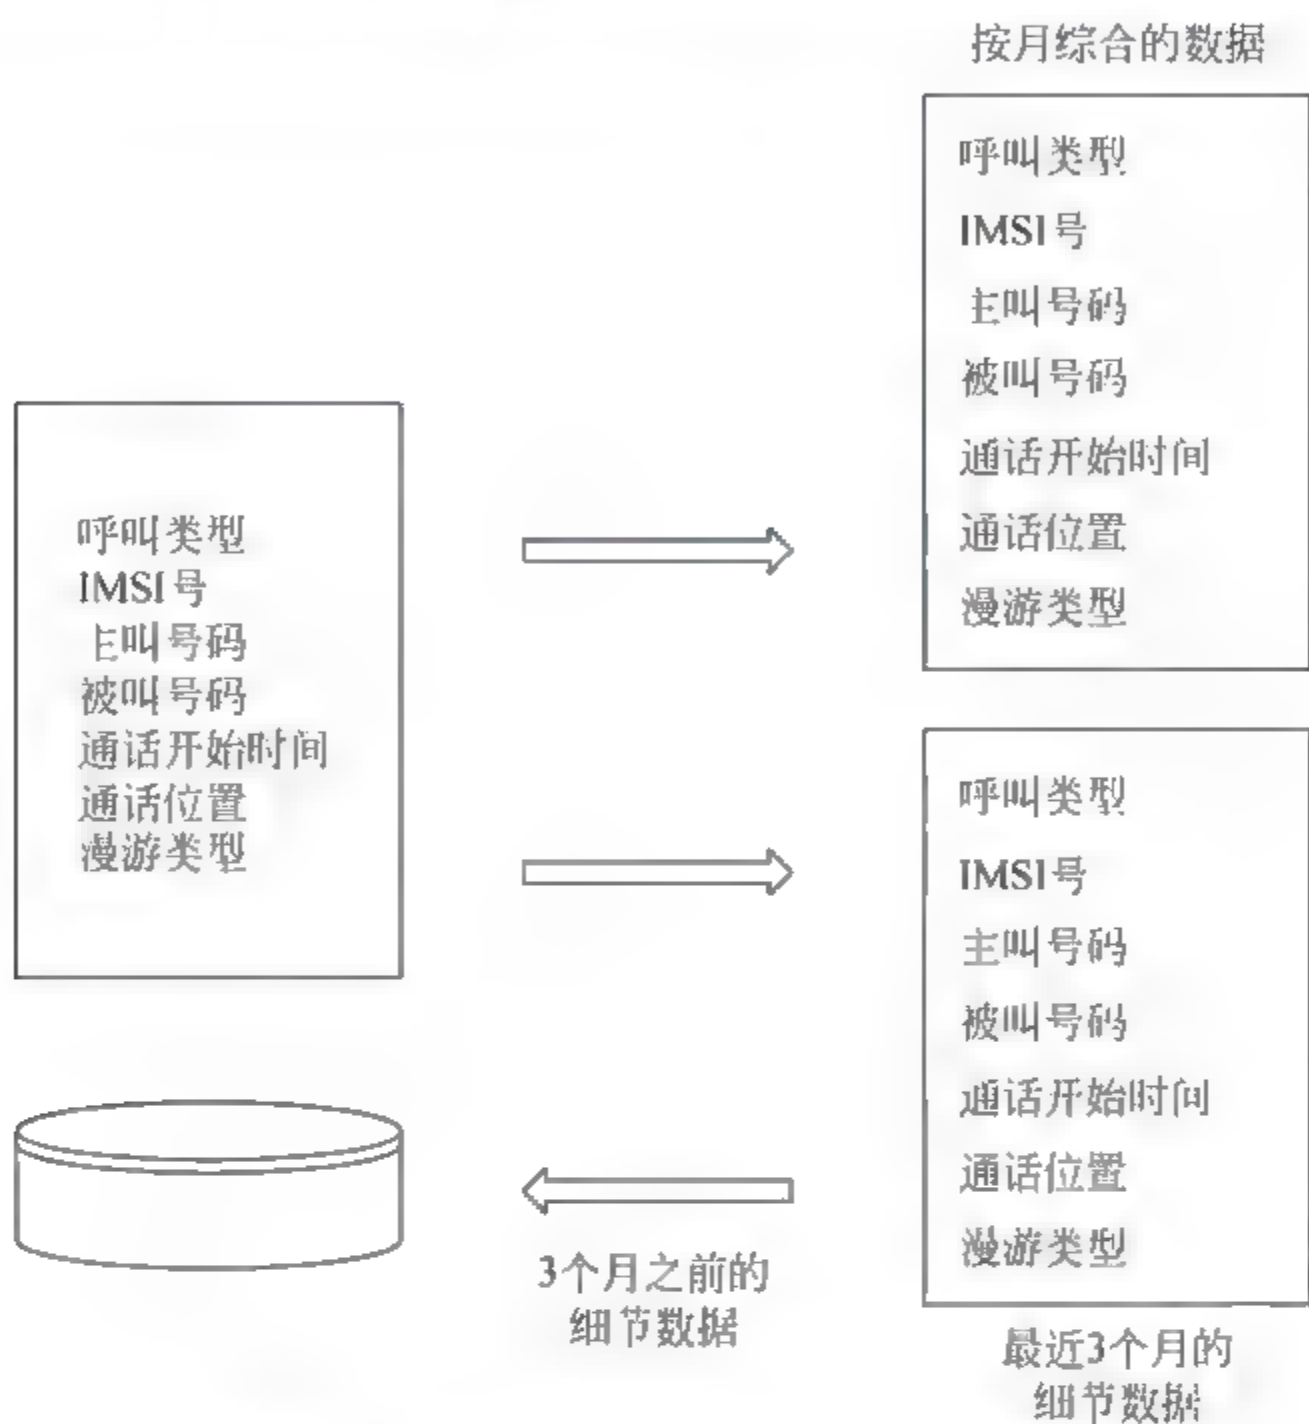


图 3.4 使用双重粒度的通话详单数据

## 2) 选择粒度级别和汇总方式

对粒度级别的选择主要根据用户的分析需求和各个表的数据量大小决定。其中用户需求主要来自在需求分析阶段获得的各种用户报表和对分析需求的描述资料。针对不同数据层次选择粒度级别如下:

(1) 当前细节级:保存业务系统的最详细数据,不进行数据汇总。

(2) 轻度综合级:按照天和月份汇总数据。其中:话单数据是按照天和月份汇总一个用户的话务数据,同时保存各种话务类型维度,由于按照这种方式汇总后的数据量仍然很大,同时有对用户的月通话时长进行分类的要求。因此,增加每天和每月每个用户的通话总次数和总时长的汇总表;账单数据是汇总一个用户一个月的费用,去掉细节表中的最小费项,改变账单数据模式,将用户标识和账期作为主键,把主要费项作为字段加以保存;欠费数据是按照天和月份对用户欠费进行一次快照,同时汇总每个用户的欠费数据;销账数据是按照天和月份汇总用户的销账数据。

(3) 高度综合级:高度综合数据一部分是对轻度综合数据按照时间汇总到年,同时由于需满足用户的分析需求,带有用户标识的汇总数据量还是很大,因此在高度综合级增加一个不包括用户标识的汇总数据以再次减少数据量,提高查询分析的效率。这部分数据模型

通过对用户已有报表的指标分析和用户提出的分析需求确定。

### 3. 设计数据模型

一般情况下,ODS 存放数据仓库的当前细节级数据,采用满足第三范式的数据模型。因为 ODS 的一部分数据如用户数据、客户数据等都需要从接口中提取变化的数据对表进行更新,因此采用满足第三范式的数据模型,可减少冗余,便于更新。同时还减少了在向 ODS 抽取数据时进行关联操作的次数。另外,由于 ODS 是作为轻度综合级数据的数据源,因此为了轻度综合级数据抽取的效率和准确性,可在 ODS 中适当引入冗余字段。

在客户主题域的轻度综合级中对每个客户的数据进行汇总,其数据量很大,例如某省 GSM 业务的客户数大约是 300 万,如果采用星型模式,由于很多维度中成员数量很少,同时轻度综合级的数据又不断增加。如果完全采用星型模式将造成数据大量冗余,增加系统存储压力。因此,对轻度综合级数据采用星型和雪花型模式的综合,将用户查询中经常用到的维度直接放到事实表,其他维度和相应的维表关联,这样既可以提高一定的查询效率,同时又不会造成过多的数据冗余。用户查询时,使用最多的是业务类型、客户所属地域和套餐信息等,以及付费方式和客户账务类型等衍生字段,因此在各个轻度综合的事实表中加入业务类型、客户所属地域、套餐以及付费方式和客户账务类型,相应的维表直接和事实表关联,其他维表需要和用户维表关联。轻度综合级的数据模式如图 3.5 所示。

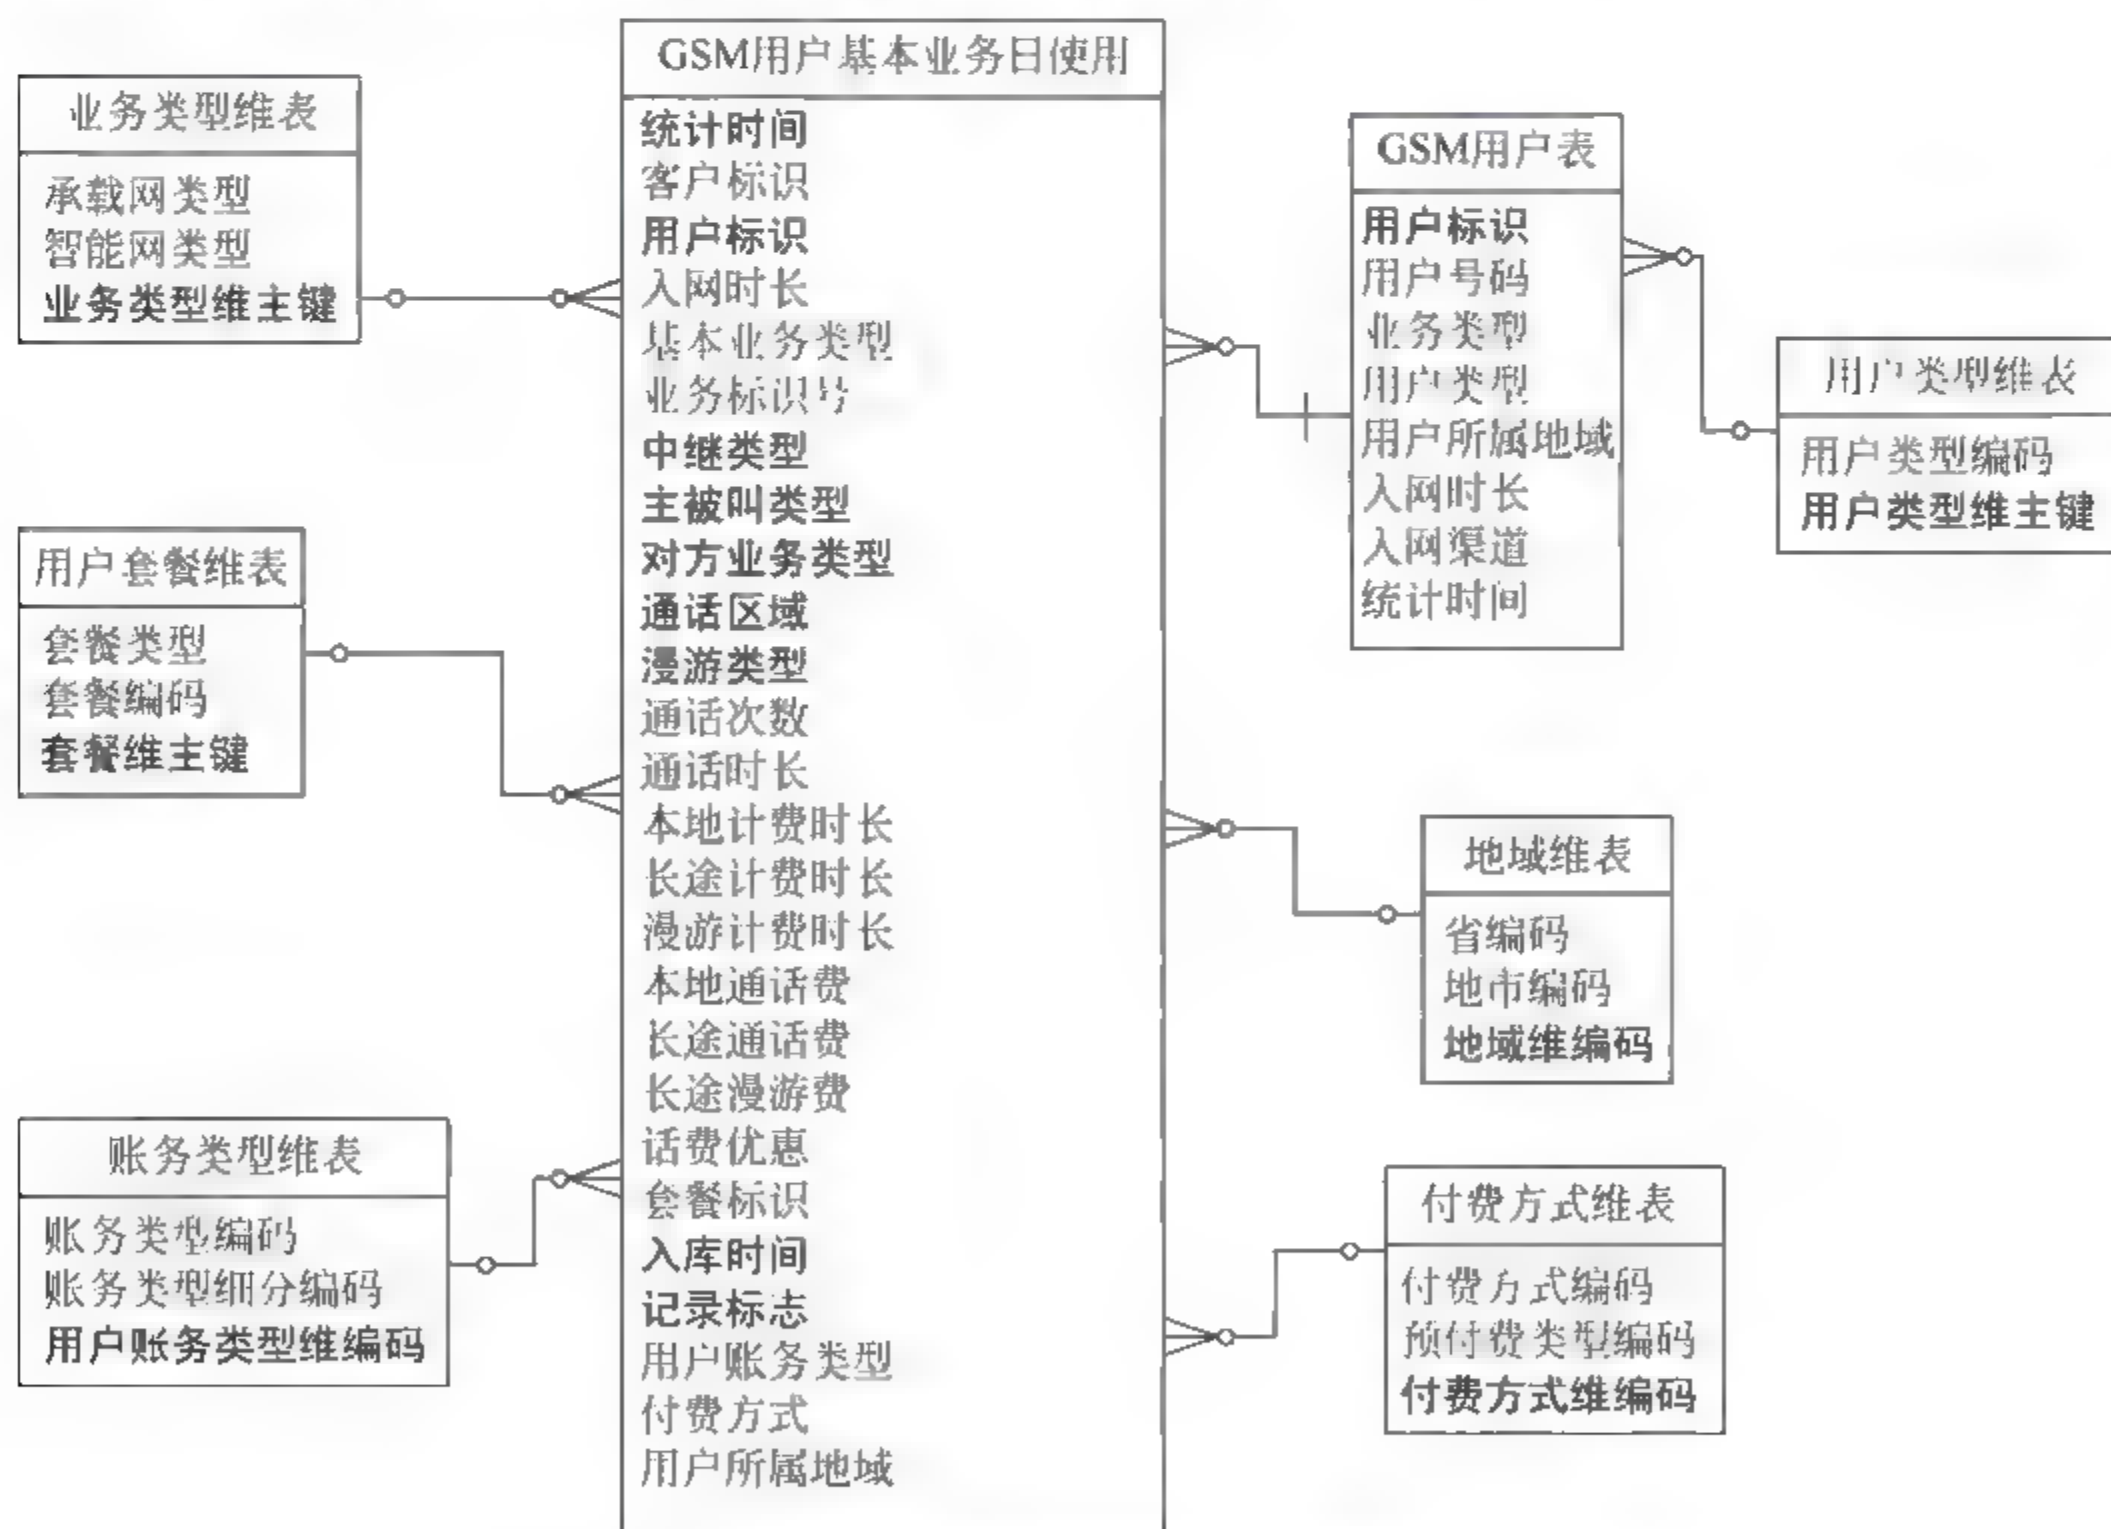


图 3.5 轻度综合级的数据模型——星型-雪花型

对于高度综合级的数据,部分是对单一用户一年数据的汇总,因此也可采用星型和雪花型组合的模式。同时,在高度综合级还有一部分是不包括用户标识的汇总数据,数据量相对

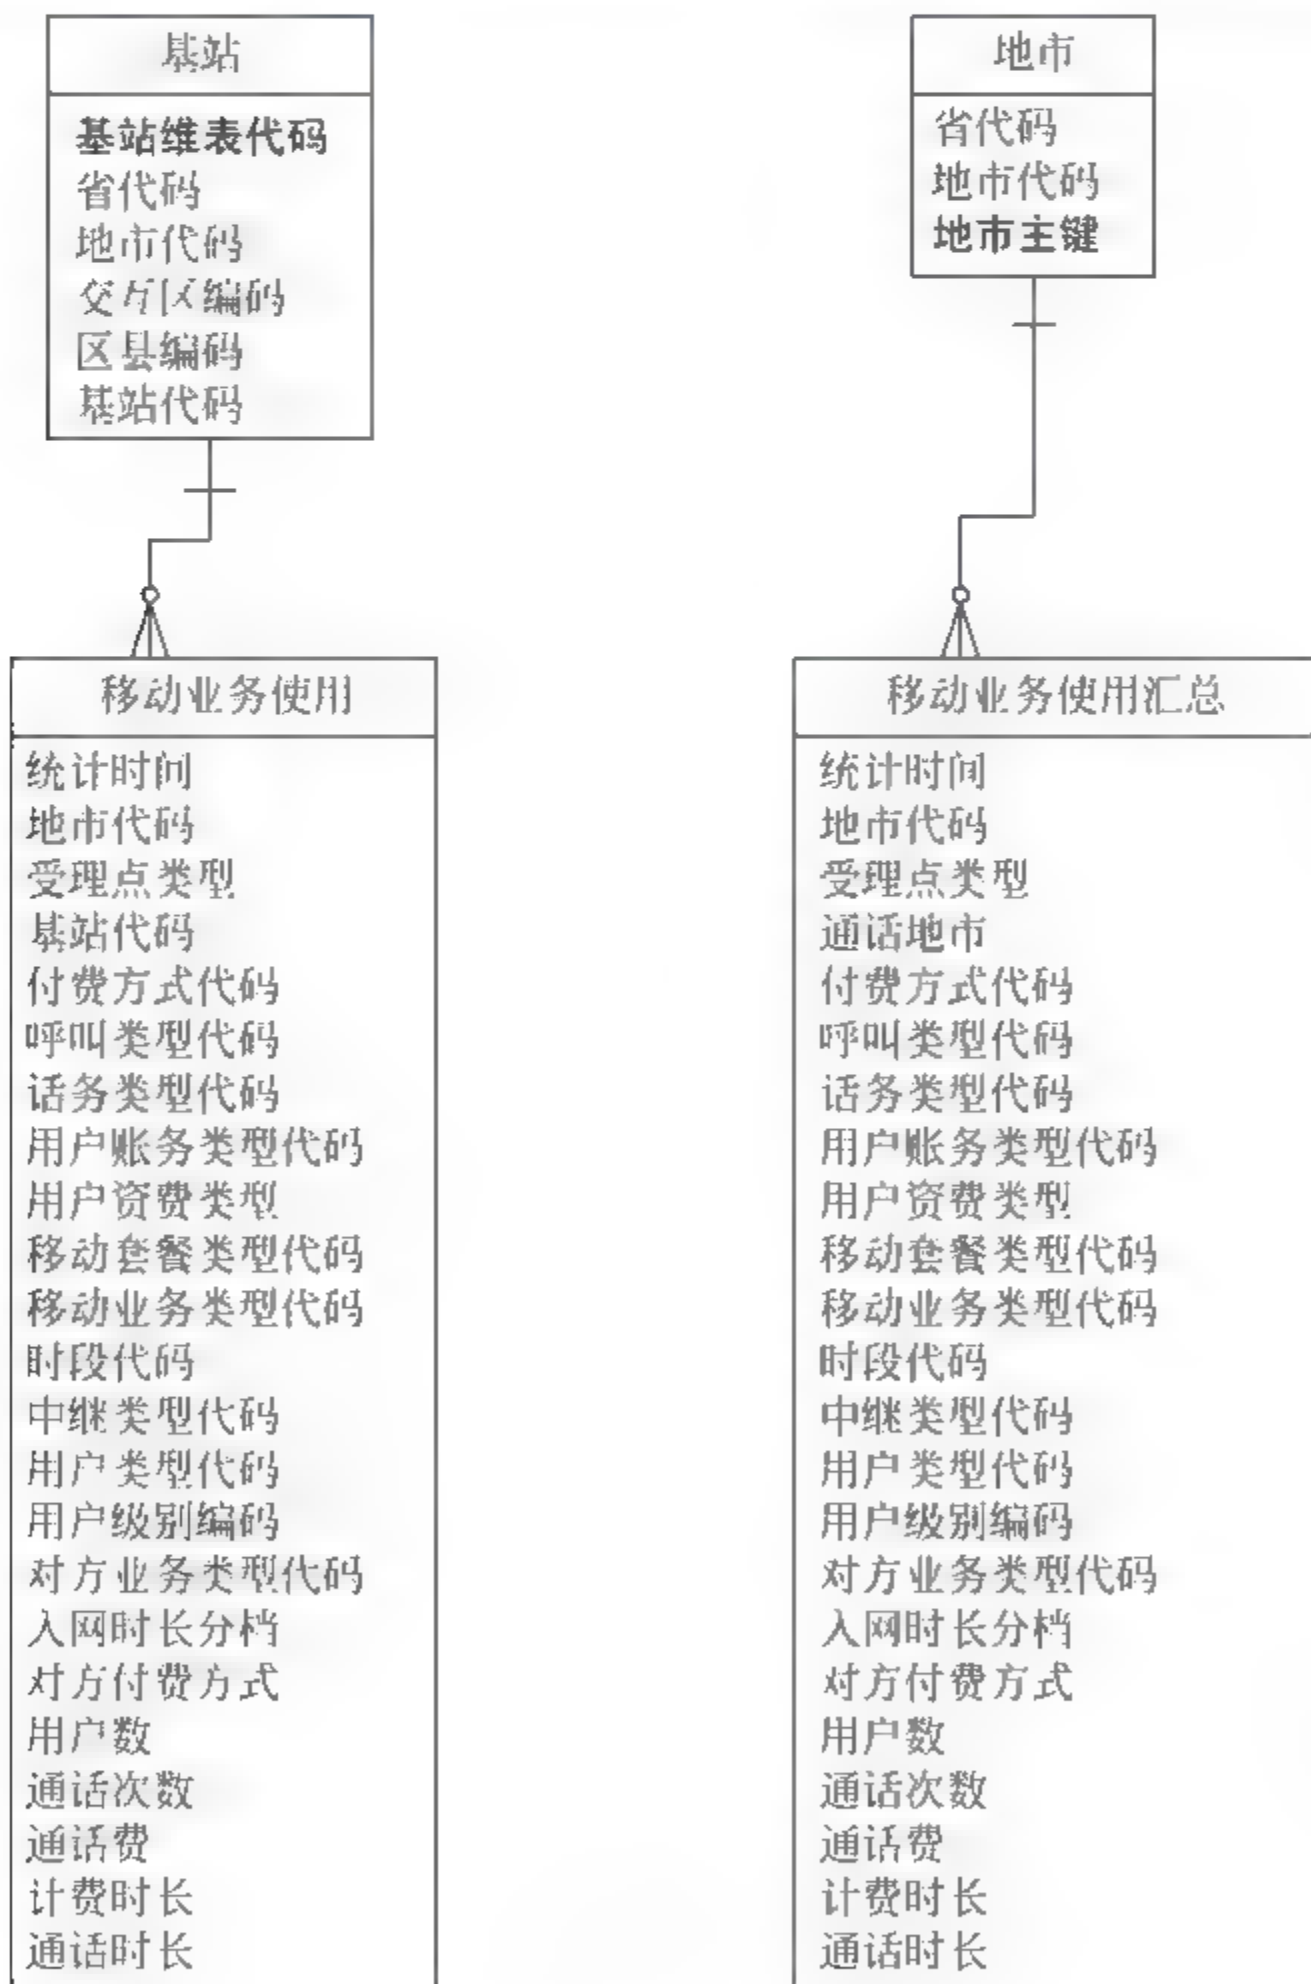
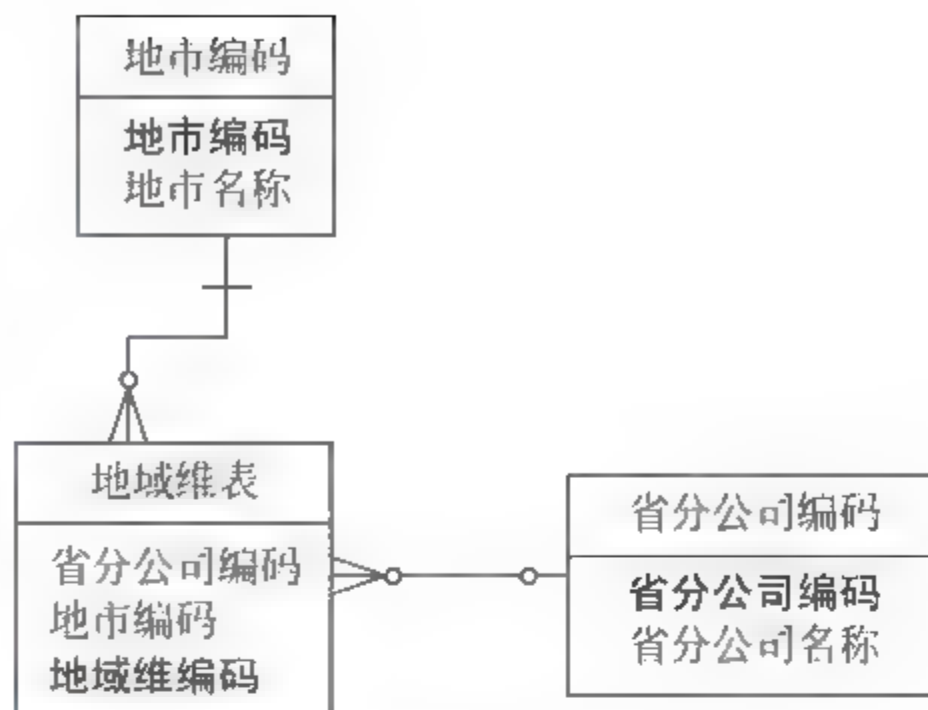


较少,因此可采用星型模式以提高数据查询效率。

设计维表时,应遵循以下的设计原则,即:

(1) 在维表中保存该维度的全部层次信息,同时引入代码表,对同一含义的字段进行统一编码,保证不同维表中相同含义的字段具有统一编码。维表和代码表的关系如图 3.6 所示。

(2) 维表只对最低层次编码,如果两个事实表对同一维度汇总到不同的层次,则对于该维度,不同的事实表对应不同的维表。例如,对于通话区域维,其层次分别为“省、地市、交换区、区县和基站”,通话情况的事实表有两个,其中一个在通话区域维的粒度是基站,而另一个在通话区域维的粒度是地市,则这两个事实表分别对应两个不同的通话区域维表,如图 3.7 所示。



采用上述方式可以避免在同一维表中保存不同层次的代码,使维表结构清晰,同时减少单一维表的数据量。另外由于代码表的存在,使得不同粒度维表中同一层次的代码统一。

(3) 除了用户维表、客户维表等业务实体对应的维表之外,维表的层次字段使用统一的命名方式,分别为 LnCODE,其中  $n$  标识是第  $n$  层编码。采用统一的命名方式便于对维表的统一维护。大部分的维表变化是指增加相应的维度取值,对此类变化主要是在代码表和维表中增加相应的代码,不会对历史数据产生影响。

#### 4. 分割数据

数据分割是指首先根据业务系统的不同对表进行分割,例如按照 GSM、增值、数据和 VoIP 等不同业务系统分割数据,这主要是基于各个不同的数据级别上都有业务维,同时不同业务除了一部分共性的数据外还包括属于该业务系统特殊的信息,因此按照不同业务分割数据一方面可以减少单表的数据量,同时可以保证数据仓库中各个业务信息的完整性。

按照业务系统分割数据后,由于话单和出账数据的单个业务的数据量还是很大,因此将话单和出账数据按照用户所属地域再次进行分割。选择用户所属地域是因为各个汇总级别上都包括用户所属地域维,按照用户所属地域分割不会对数据抽取产生影响。

#### 5. 划分表

对用户表按照其数据变化频率进行划分,大致可划分为:

(1) 比较稳定的字段,如用户标识、用户号码、用户所属地域、入网时间、离网时间、用户类型和信用额度等。

(2) 经常变化的字段,如用户套餐、用户状态和停开机时间等。

由于用户套餐在用户查询中经常使用,同时由于是每天对业务系统的用户表进行抽取,因此对话务信息而言有可能丢失用户当时通话时的套餐信息,因此将用户套餐作为冗余字段放在各个汇总的事实表中。最终将用户信息划分为两张表,即:

(1) 用户基本信息表包括用户标识、用户号码、所属地域、入网时间、离网时间、用户类型、信用额度和用户套餐等字段。

(2) 用户在网状态表包括用户标识、用户套餐、用户状态和停开机时间等字段。

#### 6. 设计多维模型

针对每个主题域确定其所需的维度和度量,然后为每一主题域定义关系模式,从而形成一个星型模式,在此基础上可以生成多维数据表,建立多维模型。

以客户主题域为例,其维度的设计如图 3.8 所示,相应的星型模式如图 3.9 所示。

在关系数据库中实现多维模型即将多维模型中的度量、维度、事实和层次等概念用关系模型中的元素实现,其实现方式可以概括为:在关系模型中维转换成维表,事实转换成事实表,度量转换成事实表中的一个字段。维表和事实表的关联是通过将维表的主键作为事实表的外键实现。



模型名称：客户资料  
模块功能：用于客户数量的分析以及客户属性的分析  
事实表：客户资料事实表  
度量：客户数量  
数据粒度：  
    每个客户每月计算一次收益,事实表中每条记录表示一个客户的属性。  
    事实表中存放1年以内的数据,超过10年的数据按月进行滚动,最初的数据汇总后从事实表中导出。  
相关维度：  
(1) 客户详细资料维  
(2) 客户性别维  
(3) 客户年龄层次维  
(4) 客户在网时间维  
(5) 客户消费层次维  
(6) 客户信用度层次维  
(7) 是否大客户维  
(8) 付费类型维  
(9) 地域维  
(10) 客户流失概率层次维  
(11) 客户挽留价值层次维  
(12) 成为大客户概率层次维  
(13) 客户价值层次维  
(14) 客户服务状态维  
(15) 客户号码维

图 3.8 客户主题域的维度设计

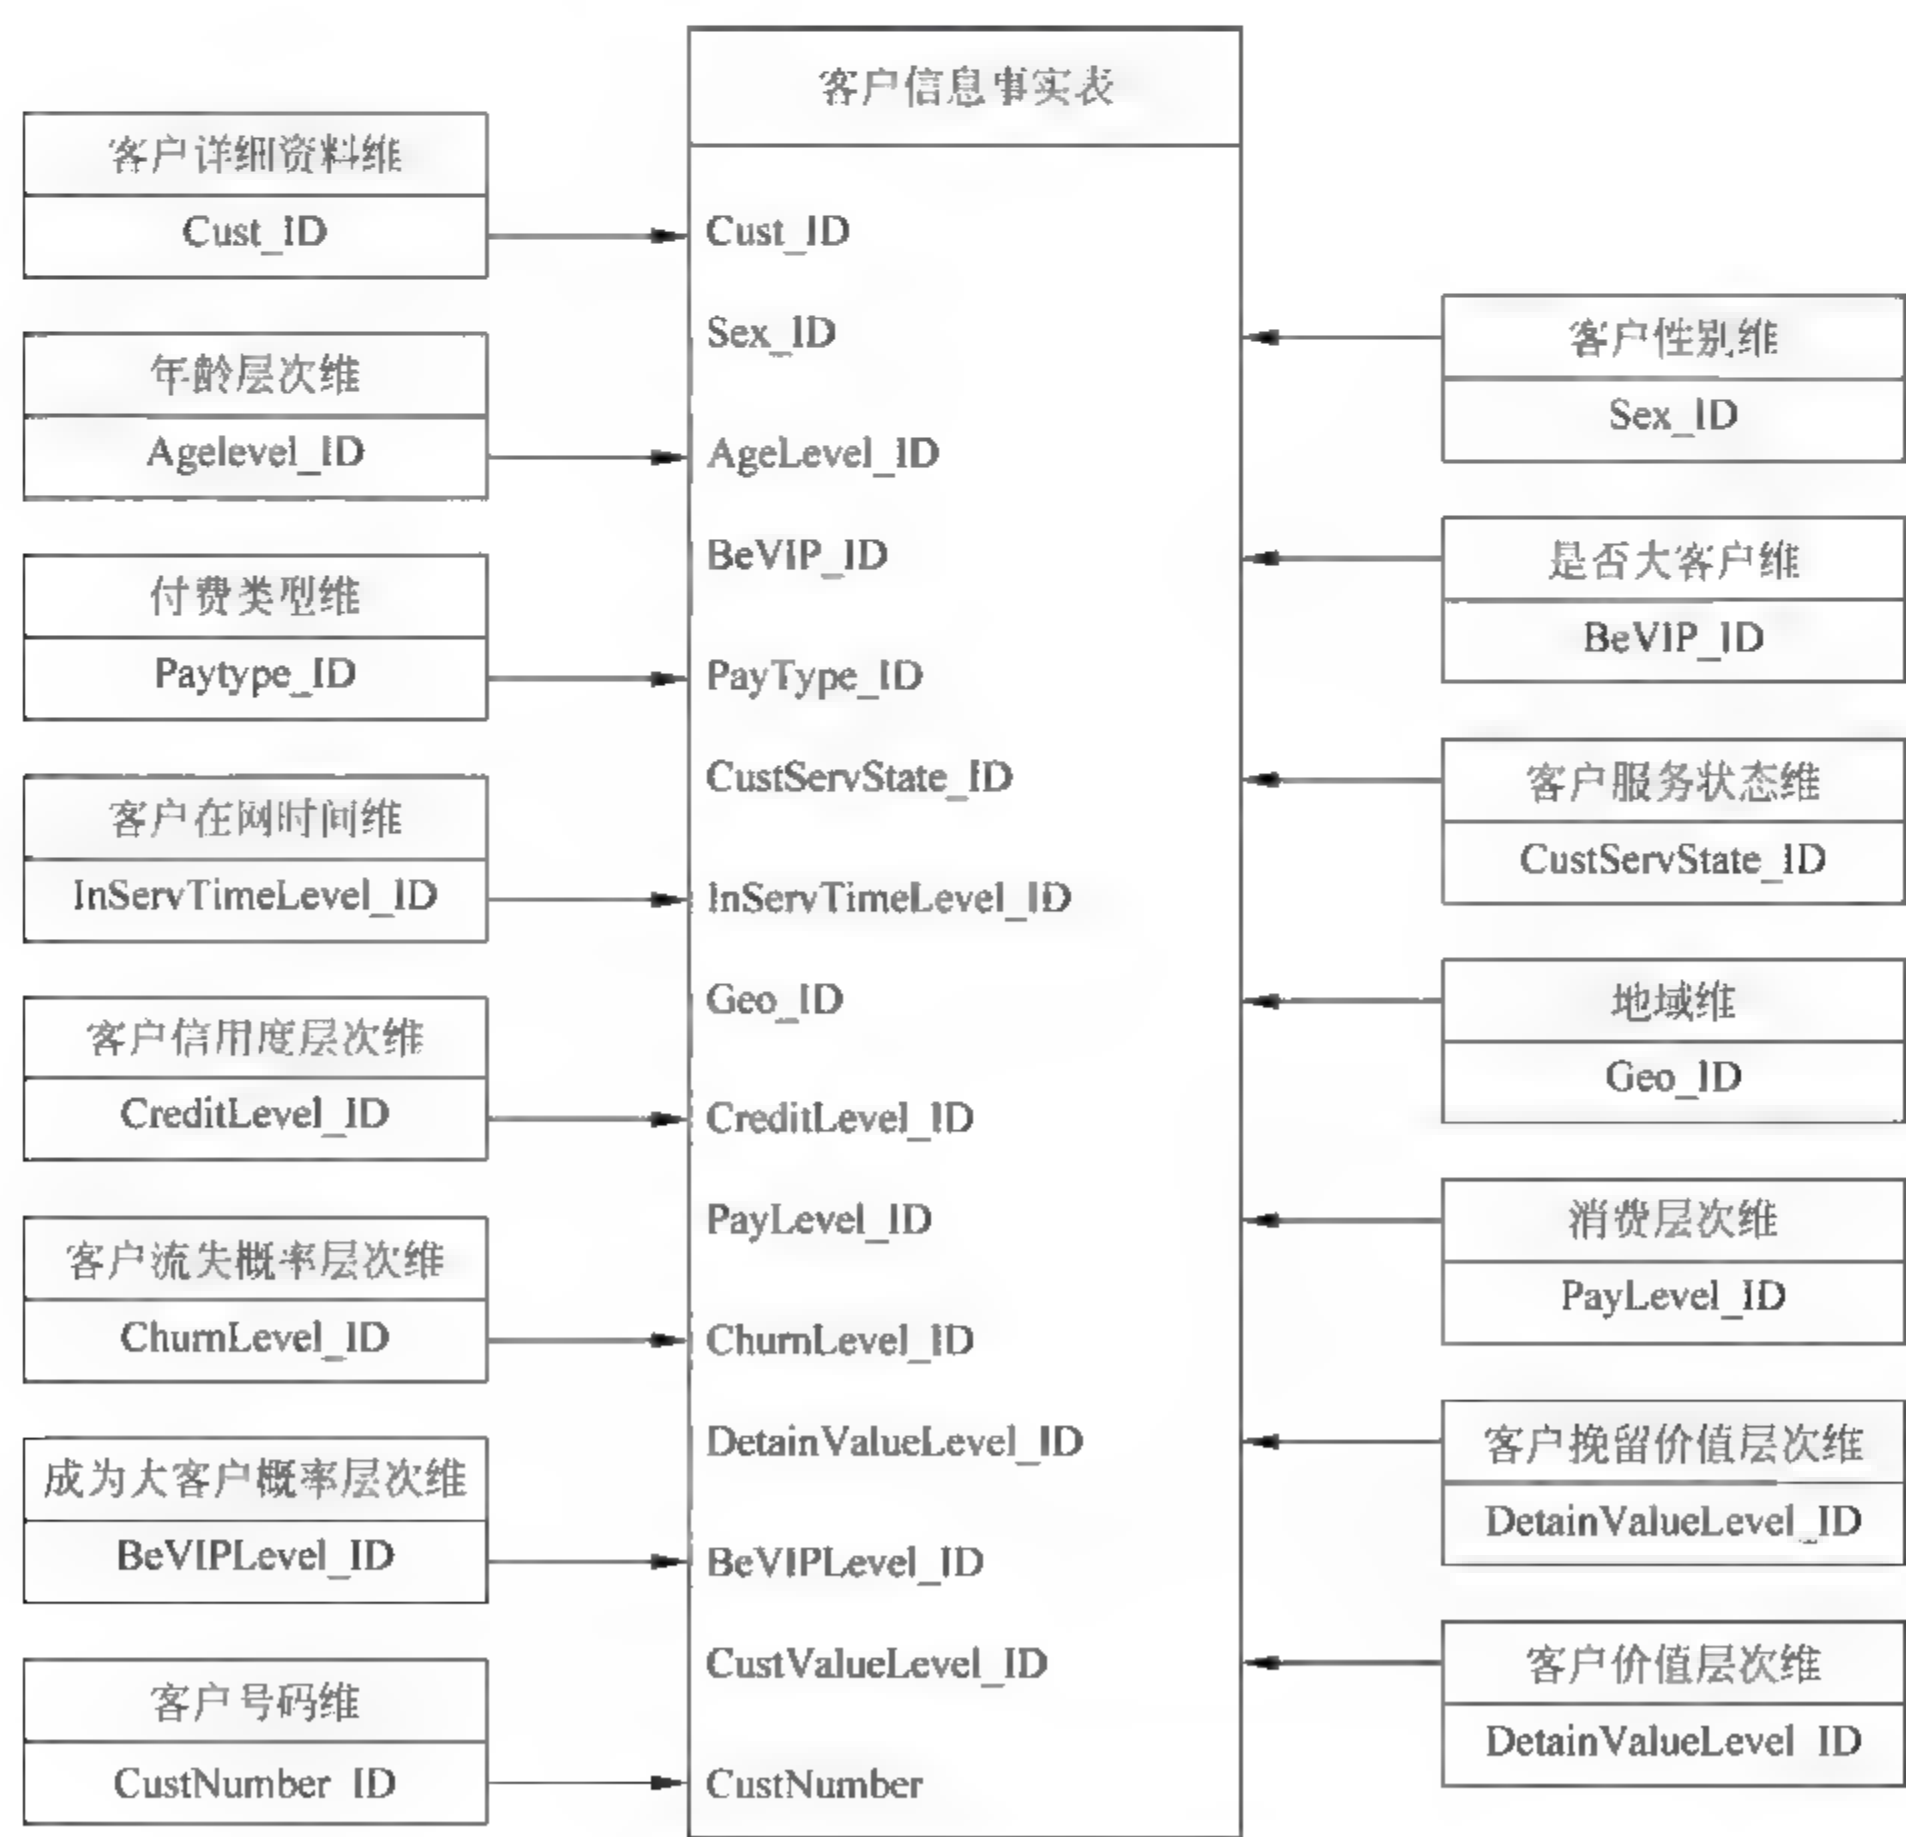


图 3.9 客户基本信息的星型模式

在使用维表实现维时,需要对维的层次进行表示,具体如下:

1) 通过维表的不同字段

通过维表的不同列表示维的不同层次。例如,地域维的层次为省、地市和区县,如图 3.10 所示。

2) 通过表之间的关联

使用不同的表分别表示维的不同层次,不同表之间通过外键关联形成维的层次。例如上述地域维的层次可以通过表之间的关联表示,如图 3.11 所示。

地域维表
省代码
省名称
地市代码
地市名称
地市维主键 <pk>
Key 1 <pk>

图 3.10 字段表示维的层次

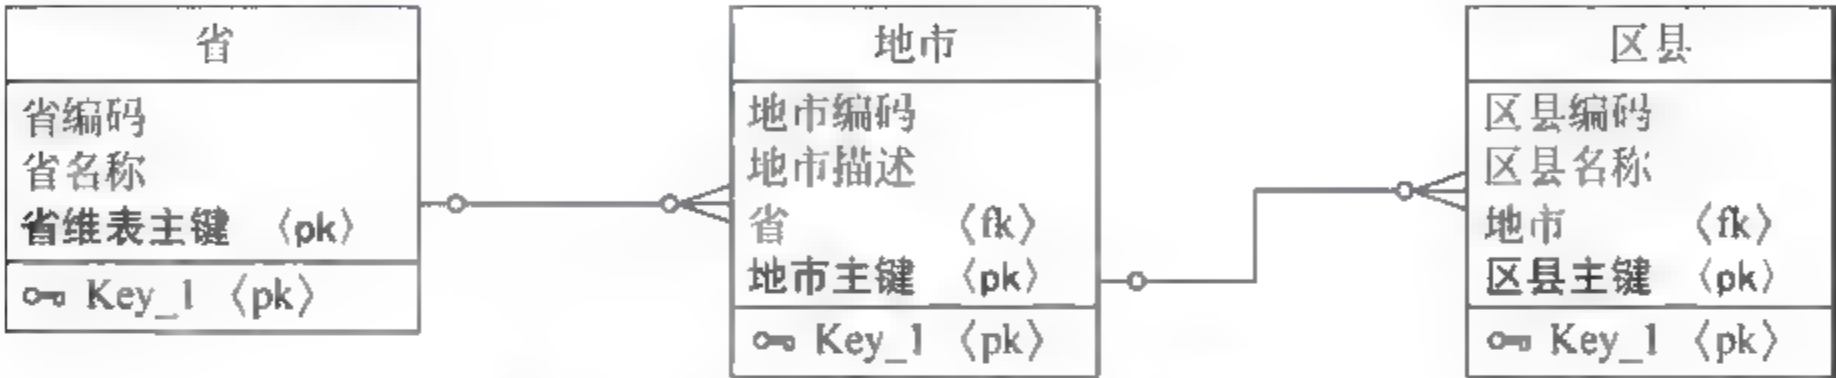


图 3.11 表之间的关联表示维的层次

3) 通过关联字段

在维表中加入两个字段,一个标识维中的成员,另一个标识该成员的逻辑父代的成员,例如上述地域维的层次可以通过关联字段表示,如图 3.12 所示。

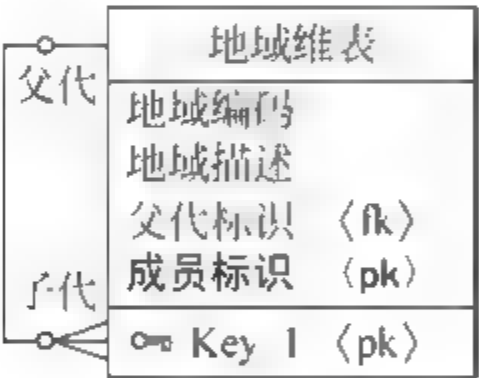


图 3.12 关联字段表示维的层次

上述各种维度层次的表示方法中,通过字段表示的方法最为简单,而且由于查询时是对单表的查询,因此查询效率较高。通过不同的表来表示维度层次可以提取出许多共用的维表,提高维表的可维护性,但是由于查询时需要多次关联,因此查询效率较低。以上两种方法对于不均衡和不整齐的维而言,都存在数据冗余,需要通过引入人工成员将维度补齐,如果维的层次较多,最终实现起来数据冗余会很大。而采用关联字段的方法,可以很好地表示不均衡和不整齐的维度,但是由于在查询时需要对表进行多次的自关联操作,因此查询效率较低,而且采用关联字段的维表也不易被用户理解。星型和雪花型模式都可以使用关联字段实现维表。

3.1.3 物理模型设计

本例中,物理模型设计主要包括以下几个方面。

1. 数据文件的存储分配

由于数据仓库中 ODS、轻度综合级、高度综合级以及维表的数据量和数据增长方式的不同,可将其划分成多个数据文件进行存储,又因为话单的数据量很大同时数据增长也很快,因此在 ODS、轻度综合级和高度综合级对应的数据文件中都指定几个文件作为话单数据专用的数据文件。

2. 表的索引

当前细节级中的用户表、欠费表加入主键索引可以提高数据更新速度。对其他的表,可以根据用户经常查询的方式以及字段本身的特性加入适当索引。



### 3. 表的物理分割

对话务和出账数据按照时间进行物理分割,使得对一天或者一个月数据的查询不受数据逐渐增加的影响。表的物理分割依赖于 DBMS 系统的功能,例如使用 Oracle 提供的分区功能对数据进行物理分割。

### 4. 禁止外键关联

将数据模型中的外键约束禁止变为人工约束,将外键禁止是为了保证数据抽取的效率,不删除外键是为了提供数据之间的关联关系。

## 3.1.4 ETL 设计

本例中,ETL 设计主要包括以下几个方面。

### 1. 抽取数据到临时存储区

数据仓库的数据源不是来自终端客户每天输入的数据,而主要来自企业 OLTP 系统的数据。

对于一个简单的面向电信领域的数据仓库,在将 OLTP 系统的数据加载到数据仓库之前,需先将其抽取到一个临时存储区,并在临时存储区进行数据清理和校验工作,待全部数据正确无误后,再加载到数据仓库,以保证数据质量。这是使用临时存储区的好处之一。

临时存储区事实上就是一个数据库,此数据库作为数据仓库的数据源,数据仓库直接从临时存储区加载数据,从而避开 OLTP 系统,避免了 OLTP 系统和数据仓库系统之间处理上的冲突,避免了 OLTP 系统因数据抽取而影响其响应时间。这是使用临时存储区的另一个好处。

临时存储区暂存将要加载到数据仓库的事实数据和维度数据,它利用关系表映射数据仓库的星型和雪花型模式。如果数据仓库是建立在 SQL Server 2000 数据库之上,则从 OLTP 系统抽取数据时,必然会用到存储过程和脚本文件。

下面将以时间维数据、客户维数据和收益事实表数据的抽取为例加以说明。

在 SQL Server 2000 中建立新的数据库,命名为临时存储区,分别建立客户维表、五一维表、十一维表和收益事实表,分别如表 3.1~表 3.4 所示。

表 3.1 客户维表

字段名	数据类型	长度	说明
客户序号	Int	4	关键字,自增
客户号	Char	4	外部关键字
客户姓名	Char	10	不允许空
客户性别	Char	2	不允许空

表 3.2 五一维表

字段名	数据类型	长度	说明
五一序号	Int	4	关键字,自增
年	Int	4	不允许空
日	Int	4	不允许空
日期时间	Datetime	8	不允许空

表 3.3 十一维表

字段名	数据类型	长度	说明
十一序号	Int	4	关键字,自增
年	Int	4	不允许空
日	Int	4	不允许空
日期时间	Datetime	8	不允许空

表 3.4 收益事实表

字段名	数据类型	长度	说明
事实序号	Int	4	关键字,自增
客户序号	Int	4	外部关键字
消费金额	Money	8	不允许空
日期时间	Datetime	8	不允许空

实现数据抽取的存储过程如下:

```

Create Procedure 客户主题抽取 as          //从客户表中抽取客户维数据
Select OLTP..客户表.客户号,OLTP..客户表.客户姓名,
      Case OLTP..客户表.性别
        When '0' Then '男'
        When '1' Then '女'
        When 'm' Then '男'
        When 'f' Then '女'
        Else OLTP..客户表.性别
      End,
Into 客户维度表 From OLTP..客户表
//从收益表中提取五一维数据
Select Datepart(yyyy, OLTP..收益表.收益日期时间),
      Datepart(dd, OLTP..收益表.收益日期时间),
      OLTP..收益表.收益日期时间
Into 五一维表 From OLTP..收益表
Where Datepart(mm, OLTP..收益表.收益日期时间) = 5 And
      Datepart(dd, OLTP..收益表.收益日期时间) >= 1 And
      Datepart(dd, OLTP..收益表.收益日期时间) <= 7
//从收益表中提取十一维数据
Select Datepart(yyyy, OLTP..收益表.收益日期时间),
      Datepart(dd, OLTP..收益表.收益日期时间),
      OLTP..收益表.收益日期时间
Into 十一维表 From OLTP..收益表
Where Datepart(mm, OLTP..收益表.收益日期时间) = 10 And
      Datepart(dd, OLTP..收益表.收益日期时间) >= 1 And
      Datepart(dd, OLTP..收益表.收益日期时间) <= 7
//从收益表中提取事实数据
Select
      临时数据区..客户维度表.客户序号, OLTP..收益表.消费金额,
      OLTP..收益表.收益时间日期
Into 客户收益事实表 From 临时数据区..客户维度表, OLTP..收益表
Where 临时数据区..客户维度表.员工号 = OLTP..收益表.客户号
    
```



在转换过程中,假设 OLTP 系统可能的性别集合为 $\{\{\text{男,女}\},\{0,1\},\{m,f\}\}$ ,则可以建立如下脚本:

```
// *****
// Visual Basic 转换脚本
// *****
Function Main()
    If (DTSSource("sex") == "0")
        DTSDestination("性别") = "男"
    Else if (DTSSource("sex") == "1")
        DTSDestination("性别") = "女"
    If (DTSSource("sex") == "m")
        DTSDestination("性别") = "男"
    Else if (DTSSource("sex") == "f")
        DTSDestination("性别") = "女"
    Main = DTSTransformStat_OK
End Function
```

例如,源数据库的客户表和数据仓库的客户维表的结构如表 3.5 所示。

表 3.5 源数据库的客户表和数据仓库的客户维表的结构

源数据库的客户表		数据仓库的客户维表	
客户识别码	Char	客户当前标志	Int(标识)
客户消费能力	SmallMoney(年收入)	客户识别码	Char
Insert_dtm	Smalldatetime	客户消费能力	Varchar(收入层次)
Update_dtm	Smalldatetime		

通过两者的比较发现客户消费能力的数据类型不一致。前者存储的是具体的收入值,后者是收入的层次,可编写如下的 VBScript 脚本完成这一转换。

```
// *****
//Visual Basic 转换脚本
// *****
//将客户表的 yearly_income 的 SmallMoney 型转换成客户维表的 Varchar 型
Function Main()
    Select Case DTSSource("yearly_income")
        Case Is <= 10000
            DTSDestination("yearly_income") = "$ 10k - "
        Case 10001 to 30000
            DTSDestination("yearly_income") = "$ 10k - $ 30k"
        Case 30001 to 50000
            DTSDestination("yearly_income") = "$ 30k - $ 50k"
        Case 50001 to 70000
            DTSDestination("yearly_income") = "$ 50k - $ 70k"
        Case 70001 to 90000
            DTSDestination("yearly_income") = "$ 70k - $ 90k"
        Case 90001 to 110000
            DTSDestination("yearly_income") = "$ 90k - $ 110k"
        Case 110001 to 130000
            DTSDestination("yearly_income") = "$ 110k - $ 130k"
```

```
Case 130001 to 150000
    DTSDestination("yearly_income") = "$ 130k - $ 150k"
Case else
    DTSDestination("yearly_income") = "$ 150k + "
Main = DTSTransformStat_OK
End Function
```

## 2. 加载数据到数据仓库

从数据源抽取数据到临时存储区后,需要加载数据到数据仓库,具体步骤如图 3.13 所示。

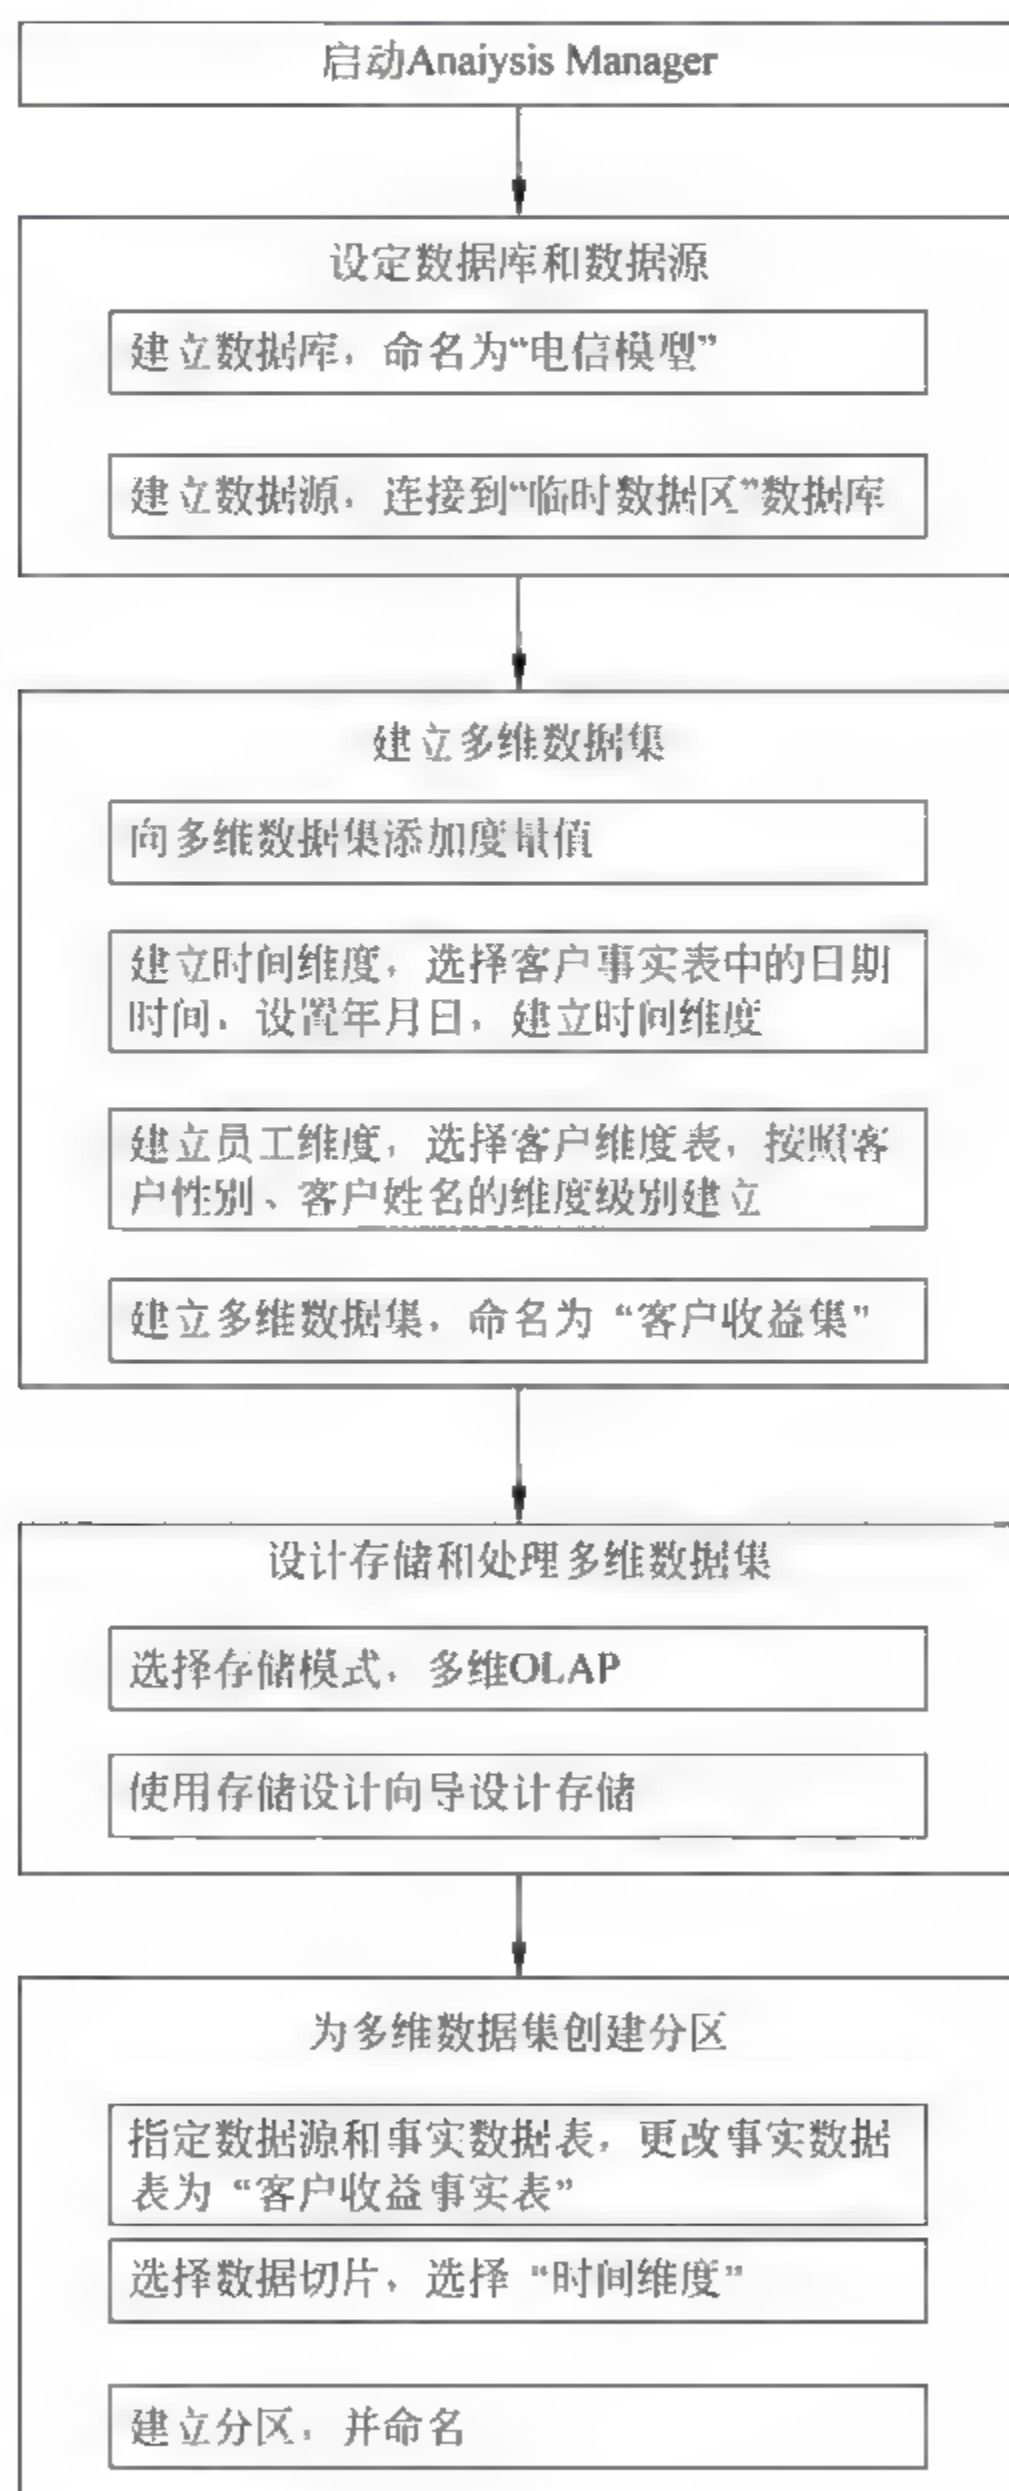


图 3.13 加载数据到数据仓库的具体步骤



## 3.2 实例二

随着数据仓库技术在金融服务业(如银行、保险等)、电信业、航空业等资金充足、信息化起步较早、迫切需要数据分析等领域的成功应用。对其他行业的众多企业而言,如何在现有数据库基础上构建数据仓库显得日益迫切。在此以某公司的数据仓库建设为例,介绍数据仓库从设计到实现的完整过程。

### 3.2.1 总体结构设计

#### 1. 设计原则

遵循统一平台架构、分阶段实施的原则,整个公司数据仓库和统计分析系统使用相同的软硬件平台,并结合业务需求及业务现状情况,分领域、分阶段实施,保证系统在将来可以平滑地进行功能增加和规模扩充。在整个设计过程中,遵循的主要原则如下:

##### (1) 系统实用原则,适应业务、技术的发展

为应对不断发展及变化的市场环境,公司的业务结构、业务流程、产品开发和市场策略也需要相应地调整和优化,随之而来的是业务部门数据需求的调整 and 变化,相应的报表、查询、统计和分析也会发生变化。因此数据仓库和统计分析系统需要具有很强的业务适应能力,能够及时将业务变化反映在报表、查询和统计中。同时,随着新技术的不断涌现,在系统的建设过程中也会出现新的概念和技术,系统在建设之前应充分考虑现有技术 & 未来技术的发展。

##### (2) 安全性和可靠性原则

可靠性方面,在业务系统数据正确完整的前提下,保证系统数据不丢失,避免数据不一致;安全性方面,在不影响性能的同时,采用根据业务需要,授权最小的原则,确保系统的内部和外部安全。充分利用现有网络等环境资源,利用成熟的图形界面技术和经验,保证用户界面友好、易于使用、维护简单。为了保证进度和质量,利用成熟工具,遵循软件工程的原则。

#### 2. 总体结构设计

总体结构设计是对建立数据仓库系统的总体描述,它从宏观和整体的角度对数据仓库系统的各个组成部分进行总体设计,并确定在设计过程中遵循的总体原则,从而保证数据仓库各个组成部分在开发过程中能够依据同样的基础和标准,在运行过程中能够相互配合。本例中,采用建立 CIF 数据仓库和 MD 数据集市相结合的方法,以及平行开发模式搭建某公司的数据仓库,其总体结构如图 3.14 所示,分为数据整合层、数据服务层和信息展现层。

(1) 数据整合层 主要完成从 OLTP 系统(包含各类数据源,如 ERP、工程项目管理系统 EPMS 和业务管理系统等)通过 ETL 工具将数据载入数据仓库。某公司 ERP 采用的是 Oracle,即 OLTP 数据源为 Oracle,由于本例中数据仓库采用 Oracle 9i 作为数据库服务器,所以可以直接通过建立数据库连接的方式增量地从 OLTP 数据源中抽取数据(ETL 采用 Oracle 存储过程)。如果 OLTP 数据源不是 Oracle,则需通过 ODBC 等方式抽取数据。



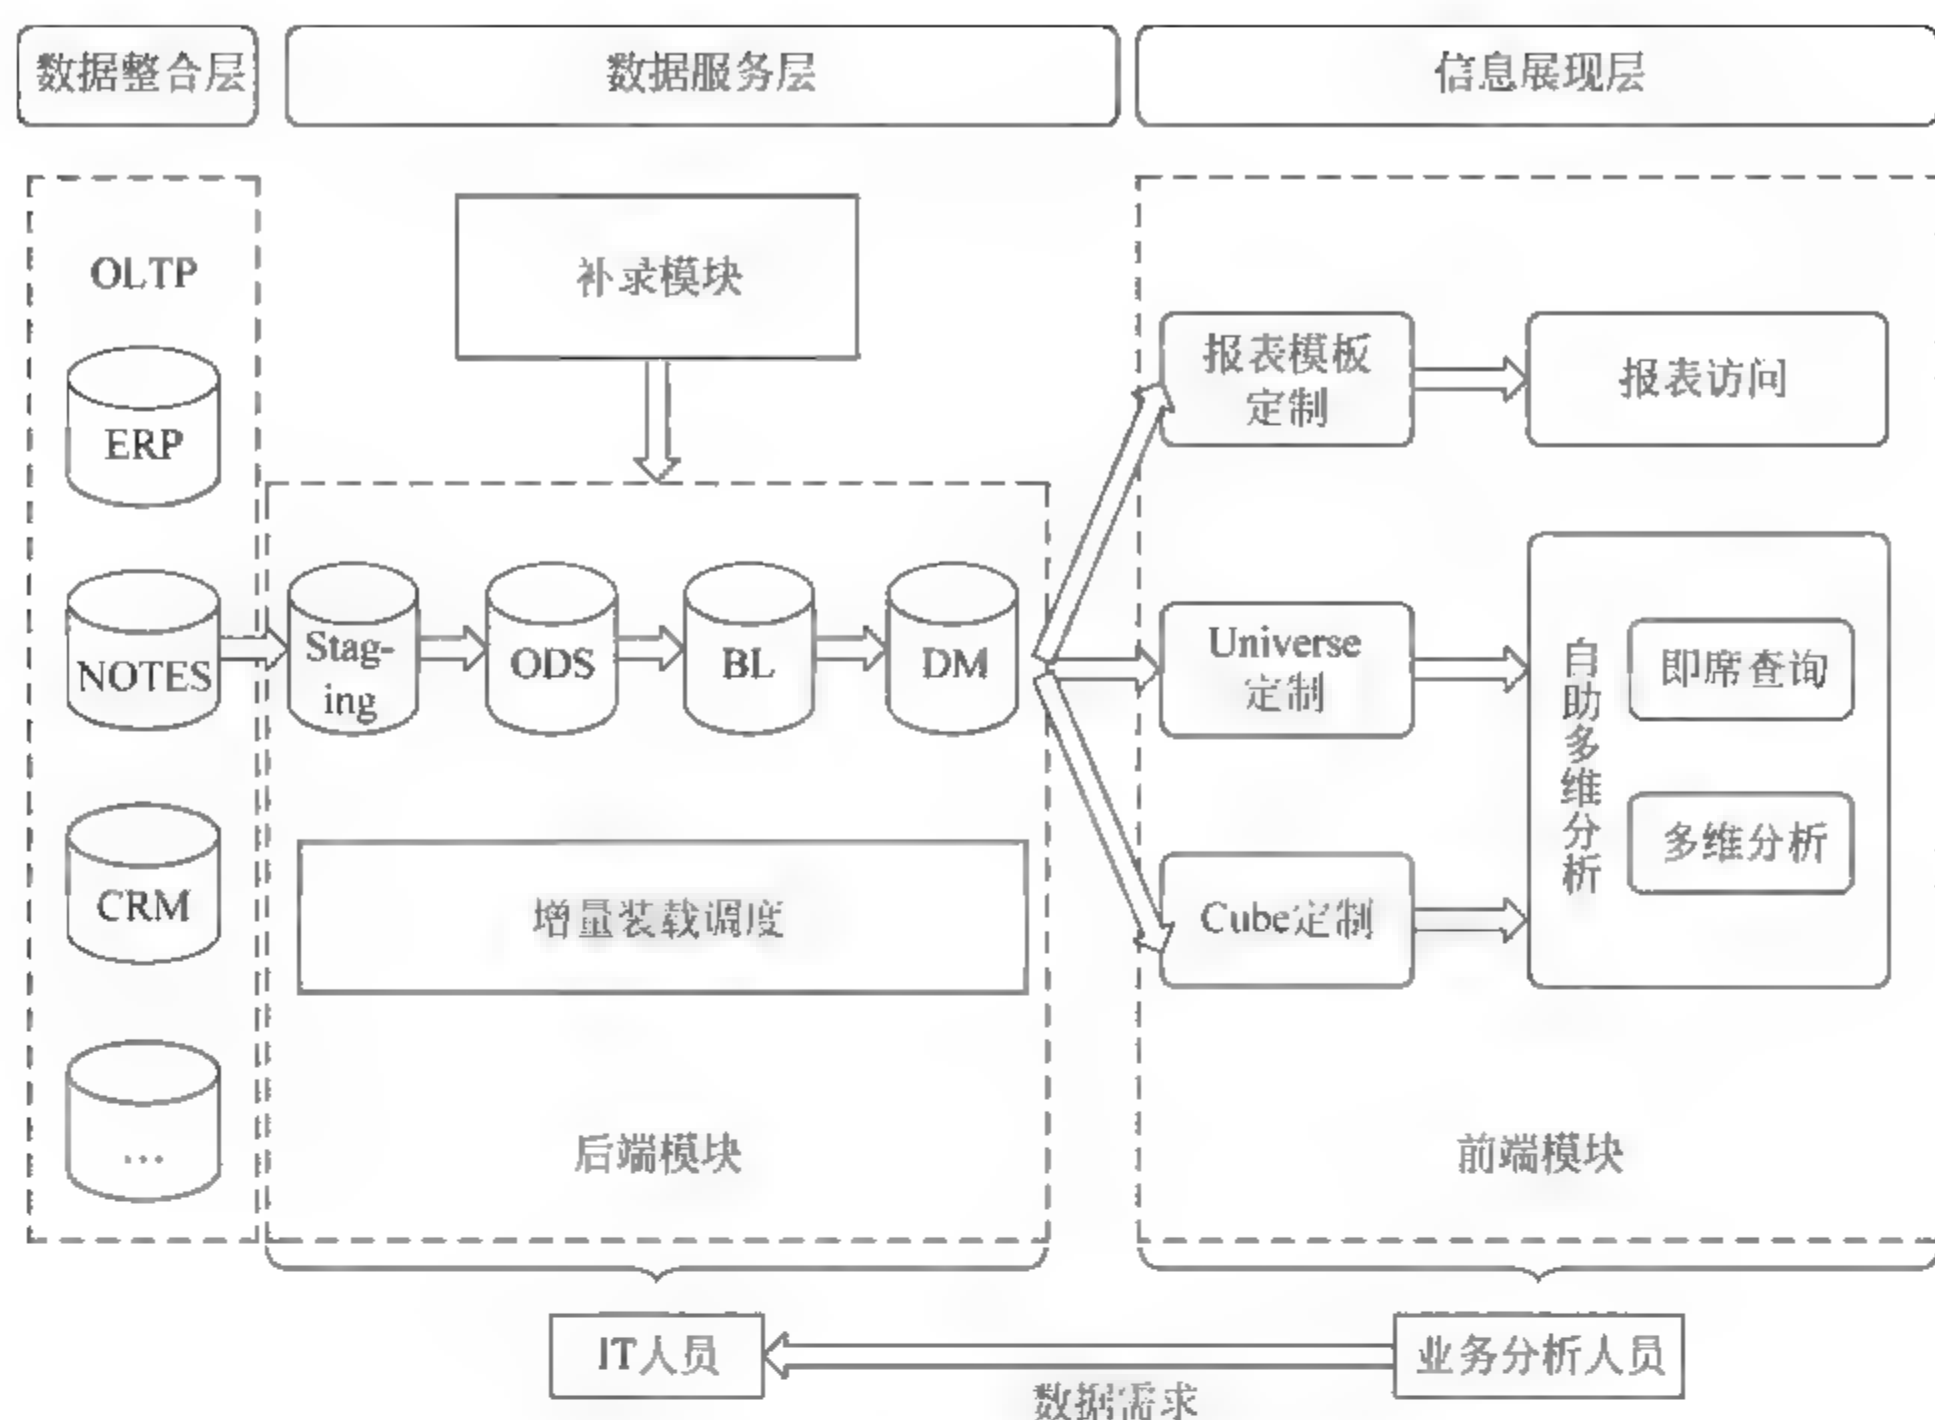


图 3.14 某公司数据仓库的总体结构

(2) 数据服务层 主要完成用数据仓库的数据分段存储。针对现有各业务系统进行数据抽取、清理并有效集成,按照主题进行组织,并建立针对主题的多维模型。考虑处理历史数据的效率及数据仓库远期规划等问题,业界通常将源系统加载到数据仓库中进行数据分层存储。在本例中,将数据服务层的数据存储划分为如下区域:

① 临时存储区(staging area)是为了保证数据迁移的顺利进行而设置的增量式的数据存储空间,它是业务系统原始数据进入数据仓库的缓冲区。需要进入数据仓库各主题域的数据首先直接快速传输到临时存储区,然后再转移到数据仓库。从业务系统(如 ERP、CRM、Notes 等)到临时存储区的传输应避免进行复杂的数据处理,以保证数据的快速导入而减少对业务系统造成压力。一般地,可以创建与 OLTP 系统实体结构相同的属性,同时在临时存储区中增加两个属性:

- Source Code 表示来源系统。
- Last Modified Date 获得数据处理时间。

如果原来的数据已经具有上述属性,则需要在新属性中增加 dw 后缀进行标识。数据成功导入数据仓库后,应清空临时存储区的数据。

② 操作数据存储区(Operational Data Store, ODS)是为了保证数据迁移的顺利进行而设置的数据存储空间,需要进入数据仓库各个主题域的数据从临时存储区直接快速传输到 ODS,再从 ODS 经过清洗、转换、映射等复杂的数据处理载入数据仓库。ODS 的数据作为数据仓库系统数据存储。逻辑上,ODS 可以分为两部分,一部分存放 OLTP 系统的历史数据,这部分需要重新考虑是否需要 OLTP 的数据进行生命周期的记录(包括交易数据与



基础数据,即缓慢变化的处理);另一部分存放数据仓库加工的信息,即 ODS 历史数据经过整合后的信息,这些信息更加全面地反映一个主题域中某一事物的全貌。

③ 中央数据仓库是具有星型或雪花型结构的实体,包括事实实体(fact entity)和维度实体(dimension entity)。其中,事实实体是对某一事物(可能是某笔交易、某个项目、某笔到货明细和某个任务)各方面信息的全面描述,描述的属性包括该事物各方面的度量信息,相关度量信息的相关维度信息;维度实体,此处的维度是与事实实体相关的维度信息,包括很多事实实体共有的维度信息,如时间维等,以及某一个事实实体专有的维度信息。中央数据仓库需要能够支持最细粒度级别,保证可以在最细粒度级别实现多维分析,即能够同时支持汇总以及明细数据的多维查询。

④ 数据集市是某一主题域的专有多维数据区,实现某一主题域的多维查询。这一部分也包括事实实体和维度实体,但与中央数据仓库不同的是数据集市的事实实体和维度实体都是为某一业务主题服务的。

(3) 信息展现层是指采用不同形式连接企业数据仓库,抽取不同的数据,主要包括即席查询、统计报表等。本例中,即席查询、统计报表采用 Business Objects 和 Web Intelligence 作为客户端,可以灵活地进行钻取、切片和旋转等多维分析的操作。

### 3.2.2 概念模型设计

数据仓库概念模型设计的目的是对数据仓库所涉及现实世界的所有客观实体进行科学、全面地分析和抽象,制定构建数据仓库的“蓝图”。在概念模型设计中,常用 E-R 图作为描述工具。E-R 图中,长方体表示实体,即表示数据仓库的主题域,框内写上主题域的名称;椭圆表示主题域的属性,用无向边把主题域与其属性连接起来;有向边表示主题域之间的联系(单向边表示一对多的关系,双向边表示多对多的关系),无向边表示主题域之间一对一的关系。在此以质量绩效分析主题为例进行概念模型设计。

质量绩效分析主要通过产品族、部门等不同角度对公司产品质量进行分析,涉及的主要绩效指标(Key Performance Indication,KPI)包括:紧急版本发布比例、版本测试不通过率、网上客户解决率、研发网上问题解决率和保修期内产品故障率等。质量绩效分析主题的概念模型如图 3.15 所示。

### 3.2.3 逻辑模型设计

逻辑模型设计是对概念模型设计中确定的基本主题域进行分析,并详细定义。本例中逻辑模型设计采用多维模型,根据具体业务的需要,设计为星型、雪花型和星型-雪花型等模式。

#### 1. 多维模型设计

质量绩效指标涉及相同的维度信息,并且计算方法相同,所以可设计相同的事实表实现对不同绩效指标的分析。由于质量绩效的研发产品维涉及产品线维、产品族维、产品开发团队维和测评产品维,所以质量绩效分析的逻辑模型采用雪花型,如图 3.16 所示。

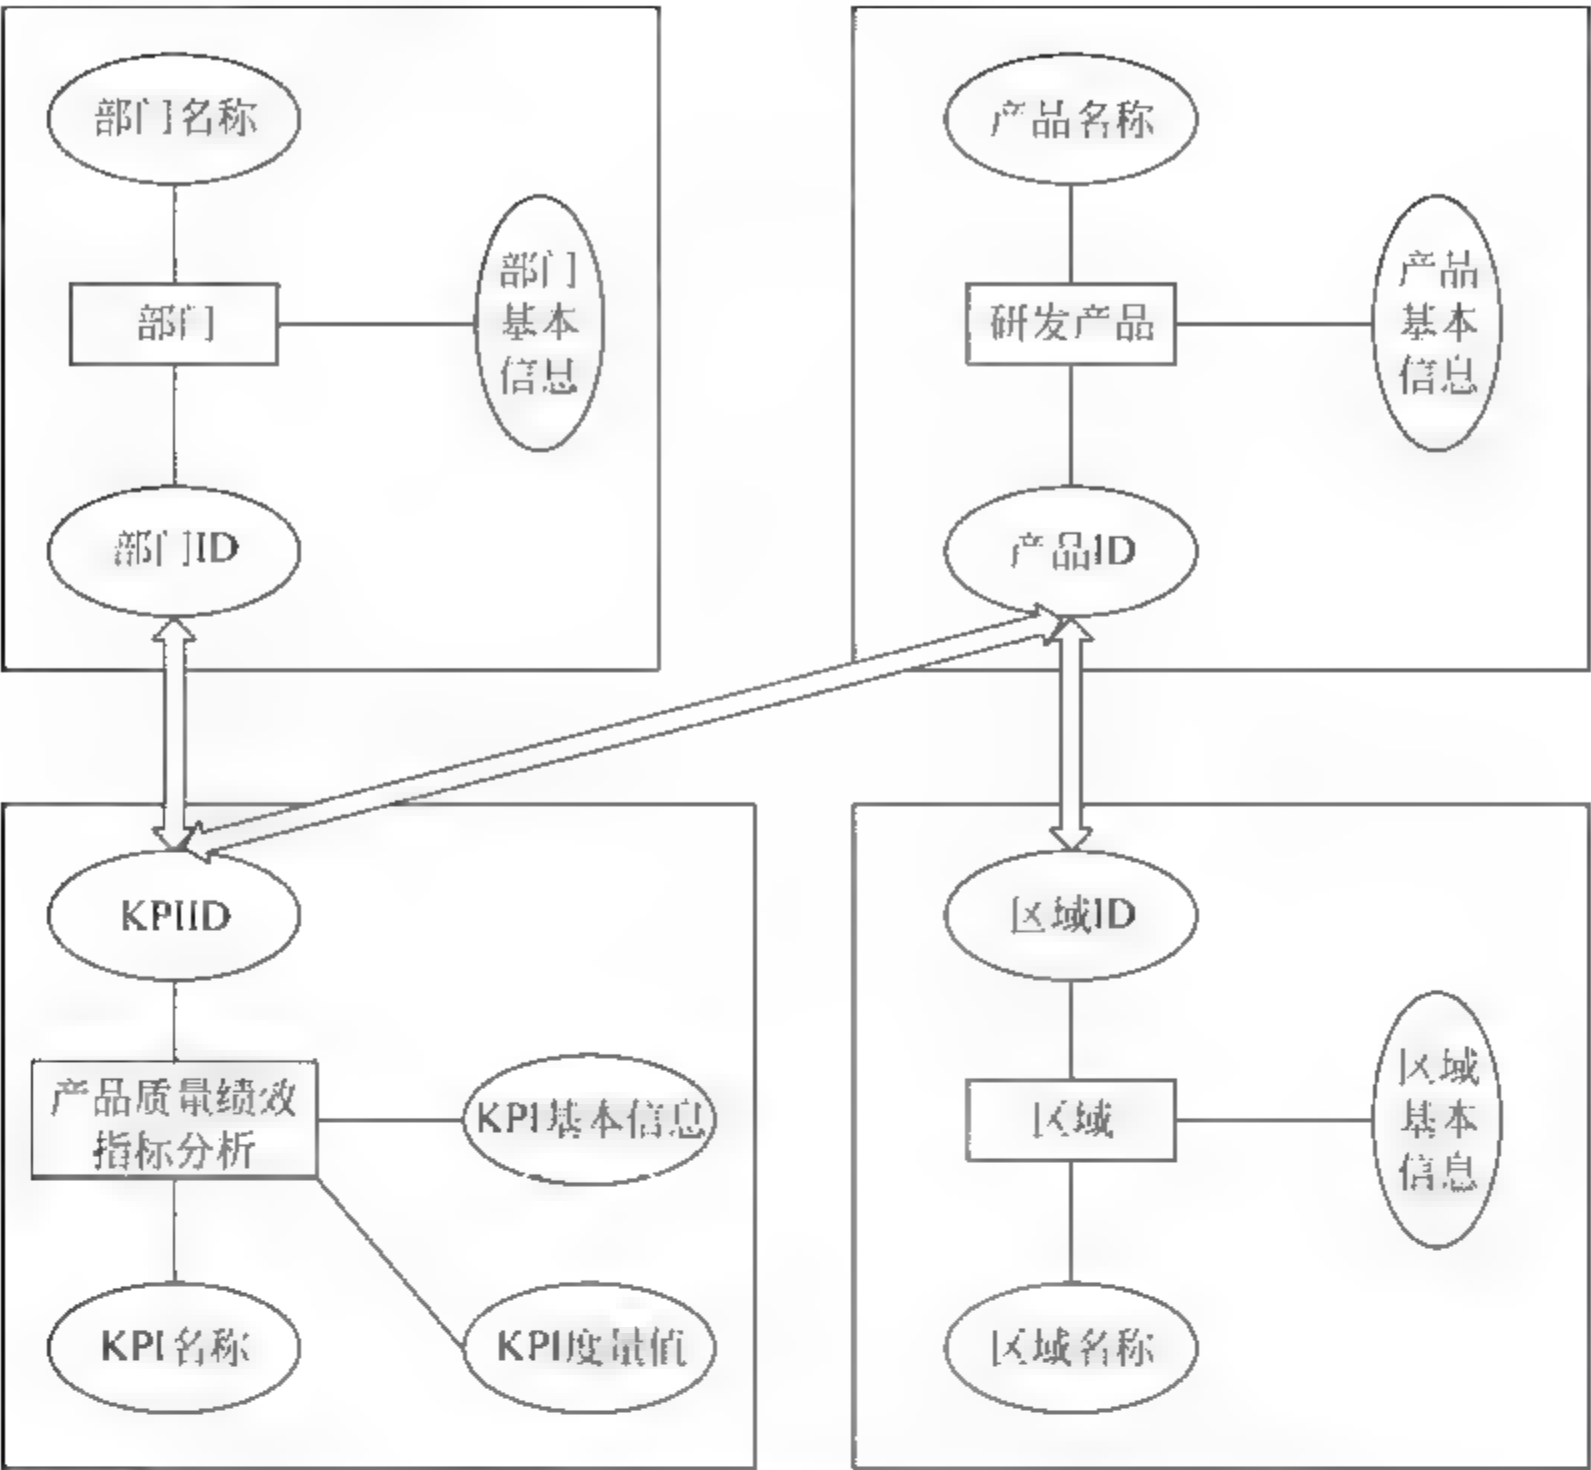


图 3.15 某公司质量绩效分析主题的概念模型

1) 时间维表

几乎所有的数据仓库都包括时间维,时间维相对独立,变化较少。本例中时间维表结构如表 3.6 所示。

表 3.6 时间维表

英文名称	中文名称	类 型	备 注
Date_key	日期键	Number	Not null
Actual_date	实际日期	Datetime	Not null
Week	周	Number	Not null
Month	月	Number	Not null
Quarter	季度	Number	Not null
Year	年	Number	Not null
Effective	状态(有效 1,停用 0)	Number	Not null
Start_Week_mark	周开始标记	Varchar2(1)	Not null
End_Week_mark	周结束标记	Varchar2(1)	Not null
Start_Month_mark	月开始标记	Varchar2(1)	Not null
End_Month_mark	月结束标记	Varchar2(1)	Not null
Start_Year_mark	年开始标记	Varchar2(1)	Not null
End_Year_mark	年结束标记	Varchar2(1)	Not null
ETL_soure_code	源系统标识	Varchar2(50)	Null
ETL_load_mark	ETL 加载标识	Varchar2(20)	Null
ETL_error_code	ETL 出错代码	Varchar2(20)	Null
ETL_loading_date	ETL 加载日期	Date	Null
ETL_update_date	ETL 更新日期	Date	Null



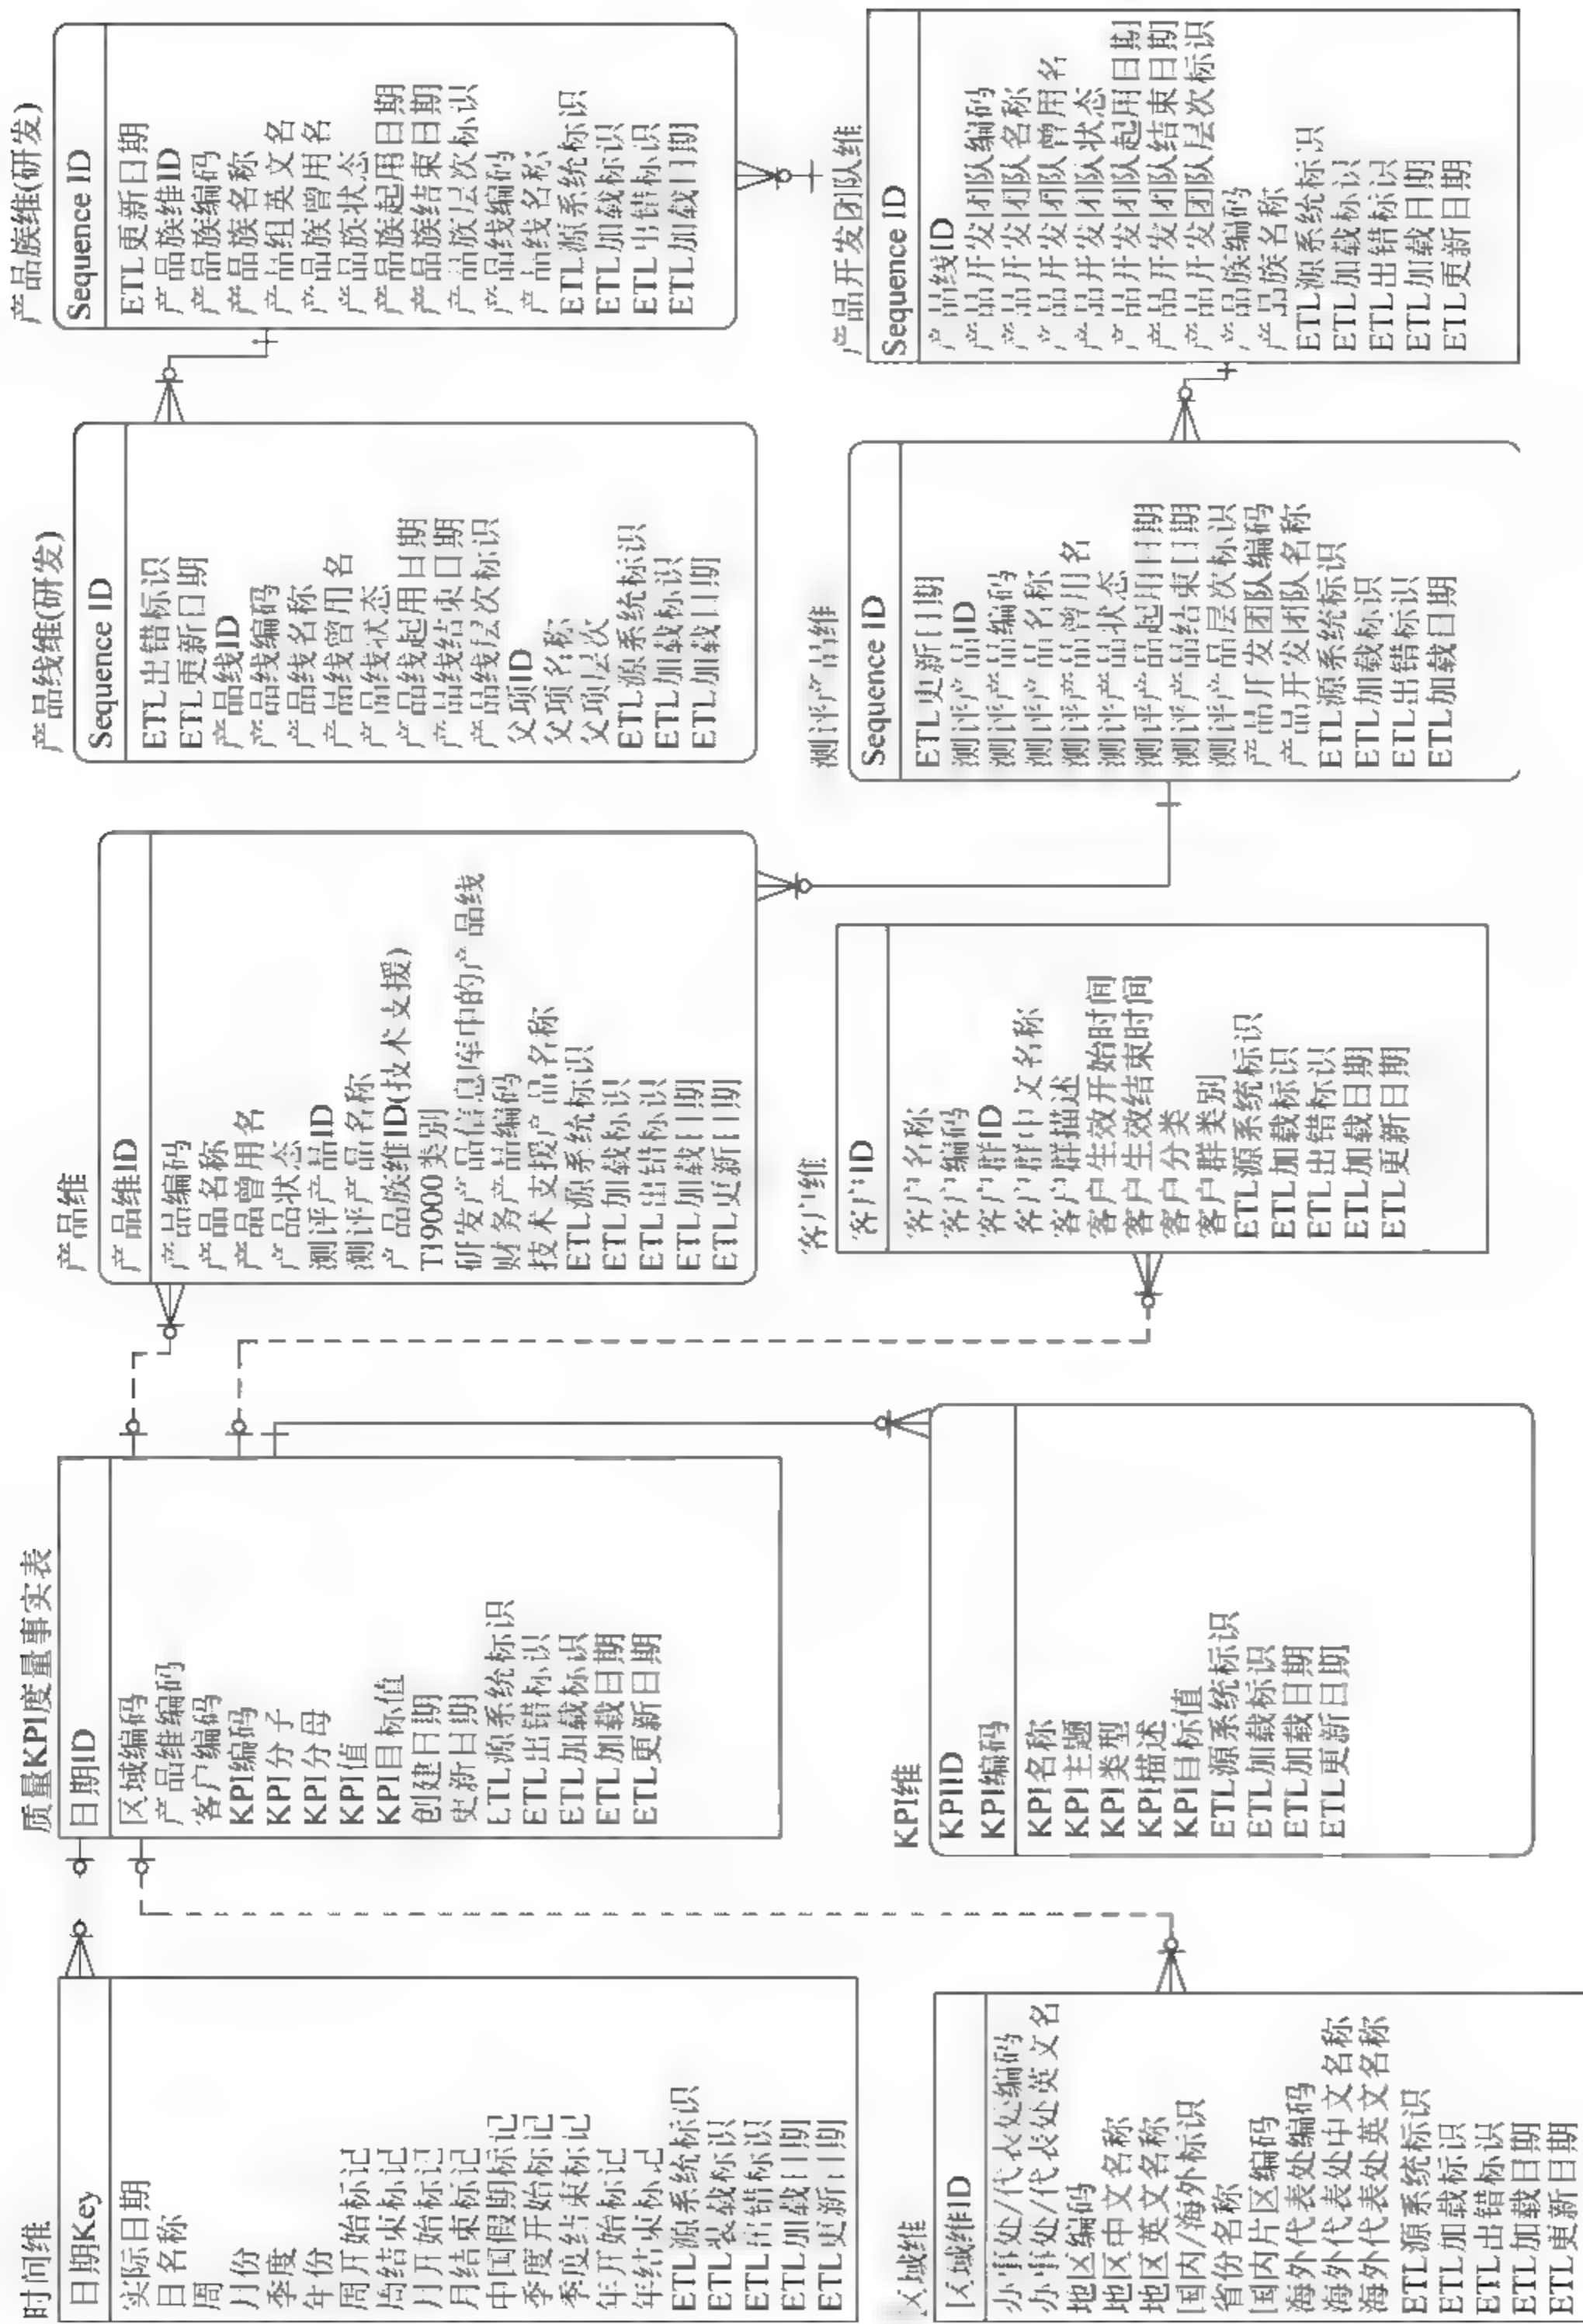


图 3.16 质量绩效分析主题的逻辑模型

2) 研发产品线维表

研发产品线维表也是大多数数据仓库都需要用到的基本维表之一,本例中研发产品线维表结构如表 3.7 所示。

表 3.7 研发产品线维表

英文名称	中文名称	类型	备注
Seq_id	序列(代理键)	Int	Not null
Product_line_dev_id	研发产品线维 ID	Number	Not null
Product_line_dev_code	产品线编码	Varchar2(20)	Not null
Product_line_name	产品线名称	Varchar2(50)	Not null
Product_line_pre	产品线曾用名	Varchar2(50)	Not null
Effective	状态(有效 1,停用 0)	Number	Not null
Start_date	起用日期	Date	Not null
End_date	结束日期	Date	Null
Level_flag	层次标识	Int	Not null
Par_id	父项 ID	Int	Not null
Par_name	父项名称	Varchar2(50)	Not null
Par_level	父项层次	Int	Not null
ETL_soure_code	源系统标识	Varchar2(50)	Null
ETL_load_mark	ETL 加载标识	Varchar2(20)	Null
ETL_error_code	ETL 出错代码	Varchar2(20)	Null
ETL_loading_date	ETL 加载日期	Date	Null
ETL_update_date	ETL 更新日期	Date	Null

值得注意的是:

(1) 研发产品线维表中缓慢变化的信息为产品线编码和产品线名称,即随着时间的变化产品线编码和产品线名称可能发生变化。如某固网产品的产品线,变化成终端固网产品线,所以应保存原来的产品信息,还要增加新的产品信息。具体处理如下:在维表加载过程通过研发产品线维 ID 检测已存在该产品线但产品线名称发生变化,可采用将原来的产品线标记为无效,即 Effective=0,同时修改 End\_date 为当前日期,新增一条记录,即 Start\_date=当前日期、End\_date=NULL、Effective=1。这样可以保留原来的产品线信息,同时又增加了新的产品线信息。

(2) 所有公共维表应存储在中央数据仓库中。

3) 研发产品族维表

研发产品族维表和研发产品线维表的关系是典型的子表和主表的关系。考虑维表维护的简单性和加载的便捷性,对研发产品族维表和研发产品线维表单独设计,而不是合并在一个维表中,本例中研发产品族维表结构如表 3.8 所示。

值得注意的是:研发产品族维表中缓慢变化的信息为产品族编码和产品族名称,其处理方法与研发产品线维相似。其中 Product\_line\_dev\_id 和 Product\_line\_name 为该产品族的产品线信息,这样可以很方便地处理某一产品族的产品线信息,在前台 OLAP 报表可以很方便地在研发产品线维和研发产品族维之间进行向上和向下钻取。



表 3.8 研发产品族维表

英文名称	中文名称	类 型	备 注
Seq_id	序列	Int	Not null
Prodfamily_dev_id	研发产品线维 ID	Number	Not null
Prodfamily_code	产品族编码	Varchar2(20)	Not null
Prodfamily_name	产品族名称	Varchar2(50)	Not null
Prodfamily_pre	产品族曾用名	Varchar2(50)	Not null
Prodfamily_name_en	产品族英文名	Varchar2(50)	Not null
Effective	状态(有效 1, 停用 0)	Number	Not null
Start_date	起用日期	Date	Not null
End_date	结束日期	Date	Null
Level_flag	层次标识	Int	Not null
Product_line_dev_id	研发产品线维 ID	Int	Not null
Product_line_name	研发产品线名称	Varchar2(50)	Not null
ETL_soure_code	源系统标识	Varchar2(50)	Null
ETL_load_mark	ETL 加载标识	Varchar2(20)	Null
ETL_error_code	ETL 出错代码	Varchar2(20)	Null
ETL_loading_date	ETL 加载日期	Date	Null
ETL_update_date	ETL 更新日期	Date	Null

#### 4) 其他维表设计

其他维表的设计可以参照研发产品线维表和研发产品族维表,不再赘述。

#### 5) 事实表设计

本例中,事实表主要包括两类:一类是保存在中央数据仓库的事实表,这类事实表存放度量的明细数据;另一类是保存在数据集市的事实表,这类事实表存放某一部门或某一领域内的汇总数据。中央数据仓库和数据集市事实表的物理结构有些是一样的,唯一区别是物理数据是分层存放的。就数据粒度而言,中央数据仓库和数据集市事实表的数据粒度也是不同的。中央数据仓库和数据集市的事实表在物理结构上有的是完全不同的,因为数据集市的数据可以直接来源于 ODS,而不是中央数据仓库;就数据集市的类型而言,数据集市可以是独立的和从属的数据集市。本例中整个数据仓库的架构非常灵活,综合了 CIF 数据仓库和 MD 数据集市的优点,可满足企业建立独立的数据集市和从属数据集市的需要。所以事实表的设计将从中央数据仓库和数据集市两方面展开。

质量绩效分析事实表结构如表 3.9 所示。

表 3.9 质量绩效分析事实表

英文名称	中文名称	类 型	备 注
Seq_id	序列	Number	Not null
Date_id	日期 ID	Number	Not null
Region_id	区域 ID	Number	Not null
Product_id	研发产品 ID	Number	Not null
Department_id	部门 ID	Number	Not null

续表

英文名称	中文名称	类型	备注
KPI_code	KPI 编码	Varchar2(10)	Not null
Prodfamily_name_en	产品族英文名	Varchar2(50)	Not null
YTD_KPI_valuenumber	上年同期 KPI 值	Number	
KPI_value_number	KPI 值	Number	Not null
Period_level	日期层次	Varchar2(10)	Not null
KPI_type	KPI 类型	Varchar2(20)	Not null
KPI_Factor1	KPI 分子 1	Number	Not null
KPI_Factor2	KPI 分子 2	Number	Not null
KPI_Factor3	KPI 分母 1	Number	Not null
KPI_Factor4	KPI 分母 2	Number	Not null
YTD_KPI_factor1	上年同期 KPI 分子 1	Number	Not null
YTD_KPI_factor2	上年同期 KPI 分子 2	Number	Not null
YTD_KPI_factor3	上年同期 KPI 分母 1	Number	Not null
YTD_KPI_factor4	上年同期 KPI 分母 2	Number	Not null
ETL_source_code	源系统标识	Varchar2(50)	Null
ETL_load_mark	ETL 加载标识	Varchar2(20)	Null
ETL_error_code	ETL 出错代码	Varchar2(20)	Null
ETL_loading_date	ETL_加载日期	Date	Null
ETL_update_date	ETL 更新日期	Date	Null

该事实表在中央数据仓库和数据集市可保持相同的物理结构,但数据集市的数据是对中央数据仓库中数据的聚合和汇总。

6) ODS 层数据结构

ODS 层数据结构见表 3.10。

表 3.10 ODS 层数据结构

ODS 表 名	源表名称
ODS_EXP_CONSIGNMENT_ORDER	EXP_CONSIGNMENT_ORDER
ODS_EXP_TRAFFIC_PLAN	EXP_TRAFFIC_PLAN
ODS_EXP_TRAFFIC_PLAN_ODER	EXP_TRAFFIC_PLAN_ODER
ODS_RCV_TRANSACTIONS	RCV_TRANSACTIONS
ODS_RCV_SHIPMENT_LINES	RCV_SHIPMENT_LINES
ODS_RCV_SHIPMENT_HEADERS	RCV_SHIPMENT_HEADERS
ODS_PO_VENDORS	PO_VENDORS
ODS_PO_HEADERS_ALL	PO_HEADERS_ALL
ODS_MTL_SYSTEM_ITEM_B	MTL_SYSTEM_ITEM_B
ODS_HR_ALL_ORG_UNITS	HR_ALL_ORG_UNITS
ODS_IBS_HKBOXLIST_DETAIL	IBS_HKBOXLIST_DETAIL
ODS_IBS_HKSENDLIST_MASTER	IBS_HKSENDLIST_MASTER
ODS_IBS_HKSENDLIST_DETAIL	IBS_HKSENDLIST_DETAIL
ODS_IBS_CORPINF	IBS_CORPINF
ODS_IBS_TRUCKCODE	IBS_TRUCKCODE



续表

ODS 表 名	源 表 名 称
ODS_IBS_HKSHIPREC_DETAIL	IBS_HKSHIPREC_DETAIL
ODS_T_PUB_DEPT	T_PUB_DEPT
ODS_T_PRODUCT	T_PRODUCT
ODS_T_REGION	T_REGION
ODS_T_ORDERS	T_ORDERS
ODS_T_ACP_INFO	T_ACP_INFO

7) 临时存储层数据结构  
临时存储层数据结构见表 3.11。

表 3.11 临时存储层数据结构

ODS 表 名	取数方式	源系统名称	源 表 名 称
EXP_CONSIGNMENT_ORDER	每天增量	EBS	EXP_CONSIGNMENT_ORDER
EXP_TRAFFIC_PLAN	每天增量	EBS	EXP_TRAFFIC_PLAN
EXP_TRAFFIC_PLAN_ODER	每天增量	ERP	EXP_TRAFFIC_PLAN_ODER
RCV_TRANSACTIONS	每天增量	ERP	RCV_TRANSACTIONS
RCV_SHIPMENT_LINES	每天增量	ERP	RCV_SHIPMENT_LINES
RCV_SHIPMENT_HEADERS	每天增量	ERP	RCV_SHIPMENT_HEADERS
PO_VENDORS	每天增量	ERP	PO_VENDORS
PO_HEADERS_ALL	每天增量	ERP	PO_HEADERS_ALL
MTL_SYSTEM_ITEM_B	每天增量	ERP	MTL_SYSTEM_ITEM_B
HR_ALL_ORG_UNITS	每天增量	ERP	HR_ALL_ORG_UNITS
IBS_HKBOXLIST_DETAIL	每天增量	ERP	IBS_HKBOXLIST_DETAIL
IBS_HKSENDLIST_MASTER	每天增量	ERP	IBS_HKSENDLIST_MASTER
IBS_HKSENDLIST_DETAIL	每天增量	ERP	IBS_HKSENDLIST_DETAIL
IBS_CORPINF	每天增量	ERP	IBS_CORPINF
IBS_TRUCKCODE	每天增量	ERP	IBS_TRUCKCODE
IBS_HKSHIPREC_DETAIL	每天增量	ERP	IBS_HKSHIPREC_DETAIL
T_PUB_DEPT	每天增量	ERP	T_PUB_DEPT
T_PRODUCT	每天增量	ERP	T_PRODUCT
T_REGION	每天增量	ERP	T_REGION
T_ORDERS	每天增量	ERP	T_ORDERS
T_ACP_INFO	每天增量	ERP	T_ACP_INFO

2. 数据粒度设计

本例中中央数据仓库和数据集市采用的是多维模型,所以数据粒度设计也是针对中央数据仓库和数据集市。中央数据仓库保存企业的业务明细数据,其数据粒度为低粒度级(高细节级);数据集市保存企业某 一部门或某 一主题的汇总或聚合数据,其数据粒度为高粒度级(低细节级)。

W. H. Immon 指出不同数量级采用的数据粒度策略如表 2.1 所示,在此数据粒度的选

择借鉴了这一数据粒度设计策略。

质量绩效分析事实表的数据在 5 年内可能膨胀到 20000000 字节,所以可考虑采用双重数据粒度,在中央数据仓库中事实表超过 5 年的明细数据可导出到后备存储设备,使中央数据仓库保存 5 年内的明细数据。其他维表的数据增量不大,可采用单一粒度。中央数据仓库的绩效分析事实表的数据粒度要达到产品层,数据集市的绩效分析事实表的数据粒度达到产品族层即可。

### 3. 分区设计

本例中,整个数据仓库采用分层存储。物理上分为四层,即 ODS、数据仓库、数据仓库聚合和数据集市。由于目前的数据量不是非常大,因此还不需要分区。但是随着数据量的增加和数据仓库的扩展,数据分区是必然的,例如可以按照时间和地域进行分区。

#### 3.2.4 物理模型设计

本例中,数据仓库物理模型设计是在 Oracle 9i 数据库基础上进行的。

##### 1. 设计原则

###### 1) 表结构设计原则

###### (1) 列的数据类型

- 数据类型建议使用 Number 型,一般不推荐使用 Integer 或 Float 型。
- 如果数据类型为字符型,一般不要使用 Char 型,建议使用 Varchar2 型。
- 一般情况下,尽量避免使用 Type、LONG、BLOB 和 CLOB 等类型。
- 如果源系统为非 Oracle 数据库,如果数据类型在 Oracle 中没有直接对应的数据类型,参考 Oracle 手册选择相近的数据类型。

###### (2) 列的长度

如果源系统的字符集和数据仓库的字符集不一致,需要考虑调整 Varchar2 的长度。如果源系统的中文存储方式为两个字节存储一个中文字符,数据仓库中表的长度应扩大(建议 3 倍)。如果扩大 3 倍后超过 4000 字节,统一定义为 4000 字节。

###### (3) PCTUSED 和 PCTFREE 参数

根据不同的要求,表可以分为三类:基本没有更新、少量更新和大量更新。临时存储区的表基本属于没有更新的类型,每次插入新数据先对表进行 Truncate,不做更新和删除操作。ODS 和中央数据仓库的表大部分属于少量更新的类型,以 Insert 为主,少量更新。数据集市的表属于大量更新的类型,主要是汇总、更新和删除操作较频繁。根据不同类型,PCTUSED 和 PCTFREE 参数建议如下:

- 基本没有更新 PCTUSED=90,PCTFREE=0
- 少量更新 PCTUSED=80,PCTFREE=10
- 大量更新 PCTUSED=70,PCTFREE=20

###### (4) PARALLEL 参数

为了提高性能,可以考虑使用 PARALLEL 参数,语法为 PARALLEL(DEGREE n),n 应该与表空间的数据文件数量一致。如果表空间的数据文件为 5 个,设置为 PARALLEL(DEGREE 5)。由于使用并发方式需要较多的系统资源,建议在需要提高性能时才使用,一



般情况不建议使用,设置为 NOPARALLEL 即可。

#### (5) LOGGING 参数

数据仓库中一般不需要进行 Log 处理,设置为 NOLOGGING 即可。

#### (6) 键设置

在数据仓库表的设计中,不建议为表创建主键或外键,如果需要进行约束,使用唯一索引或程序逻辑等方式代替主键或外键。如果必须创建主键,在定义主键时先创建唯一索引,再创建主键,不要直接创建主键。

#### (7) 表空间参数

表空间参数务必和 Schema 的缺省表空间一致,且不要与索引共用表空间。

#### (8) 表存储参数

表的初始大小建议设置为预计大小的 1/5~1/3,扩展参数可以不设置。

### 2) 表物理设计原则

表物理设计原则如表 3.12 所示。

表 3.12 表物理设计原则

设计项	内 容
索引 PCTFREE 参数	索引 PCTFREE 建议为 30
索引 PARALLEL 和 LOGGING	索引 PARALLEL 和 LOGGING 与表的相关参数设置原则相同
索引存储参数	建议初始设置为预计大小的 1/3
位图索引	在数据仓库中,有时需要设置位图索引,一般不建议使用,使用前先综合评估影响
创建脚本	表和索引的创建脚本必须包括 Schema,指定完整参数,不要遗漏表空间参数

## 2. 物理模型设计

### 1) 临时存储区的物理模型设计

#### (1) Schema list

STAGE,数据表空间: STAGEA,索引空间: STGNDX。

#### (2) 表结构和索引

临时存储区中表结构基本和源系统对应表一致,表名一般相同,可参考逻辑模型设计中临时存储区的数据结构。一般情况下临时存储区的表不使用索引。

### 2) ODS 的物理模型设计

#### (1) Schema 表

ODSML,数据表空间: ODSMLDAT,索引空间: ODSMLNDX。

#### (2) 表结构和索引

ODS 的表结构和临时存储区的表结构基本一致,可参考逻辑模型设计中 ODS 的数据结构。

### 3) 中央数据仓库的物理模型设计

#### (1) Schema 表

BLML,数据表空间: BLOMDAT,索引空间: BLOMNDX。

#### (2) 表结构和索引

对于缓慢变化维,要为所有缓慢变化的列建立唯一索引。

#### 4) 数据集市的物理模型设计

##### (1) Schema 表

DMML,数据表空间: DMMLDAT,索引空间: DMMLNDX。

##### (2) KPI 事实表结构和索引

数据集市的 KPI 事实表由于更新较多,PCTUSED 70,索引 PCTUSED 要求与表的一致。

### 3.2.5 数据清洗设计

为了保证数据仓库的数据质量,对正式进入数据仓库的数据必须采用有效的方式进行检查。如前所述,通常数据清洗可购买专用工具,也可以通过编码实现。本例中,采用 PL/SQL 编程对 ODS 的数据进行清洗,由于数据仓库中数据质量涉及方方面面的问题,在此着重阐述接口数据的检查,从而解决数据仓库“垃圾进,垃圾出”的问题。

#### 1. 清洗内容

本例中数据源主要来自 ERP 和其他管理信息系统,涉及的清洗内容包括:

(1) 实体完整性检查。如研发产品维中的产品代码不能为空,产品的状态只能为 1 或 0,不能为空等。

(2) 参照完整性(referential integrity)检查。如研发产品族维表中的产品线编码是研发产品线维表的外键。

(3) 业务规则的检查。如产品返回率的返回日期必须大于产品的发货日期。

#### 2. 清洗规则设计

数据清洗逻辑模型如图 3.17 所示,其中表 CHK\_RULE\_DEF、表 CHK\_TABLE\_RULE\_DEF、表 CHK\_FIELD\_RULE\_DEF 和表 CHK\_REFERENCE\_KEY 用来保存数据清洗所用的元数据,数据清洗元数据是在程序中创建初始脚本实现的。通过元数据定义可以灵活驱动多种数据清洗规则。表 CHK\_CHECK\_STATUS、表 CHK\_EXCEP\_LOG 和表 CHK\_ERROR\_LOG 用来保存数据清洗程序的执行状态和执行每项清洗规则的检查结果。

### 3.2.6 ETL 设计

完成上述设计,即完成了搭建存储企业数据的“仓库”,但真正发挥所搭建“仓库”的作用,必须为其装入大量有价值的数据。通常企业数据源的数据格式存在很大的差异,为了保证数据仓库的数据完整性,ETL 实现数据的抽取、转换、清洁和装载,最终利用分析工具实现数据分析,支持企业经营决策。

本例中,ETL 工具采用 CA 公司的 Advantage Transformer Script Manager2.0(简称 ADT),数据库为 Oracle 9i。



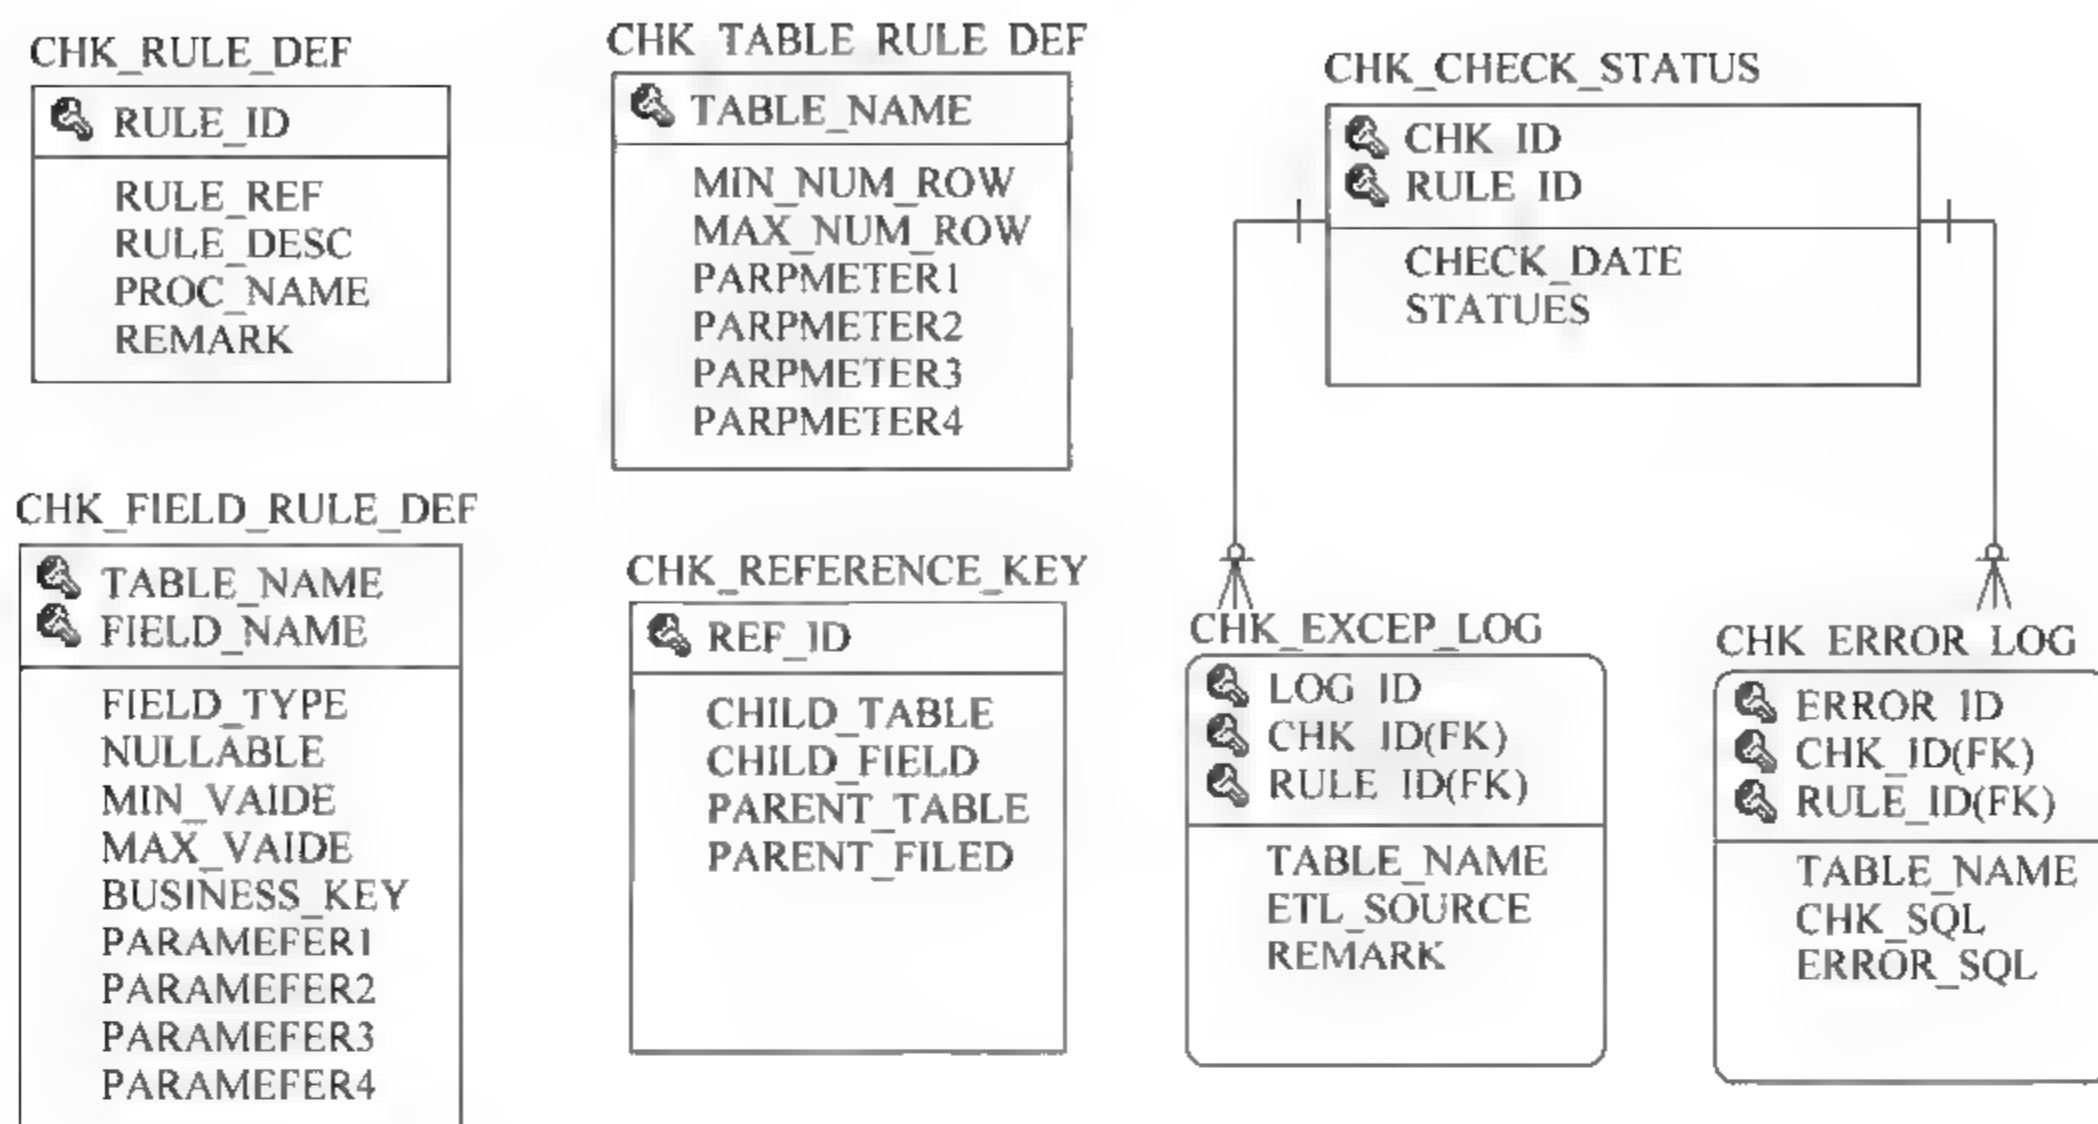


图 3.17 数据清洗逻辑模型

### 1. 数据抽取

从外部源系统加载数据到数据仓库的临时存储区,可以通过 SQL \* Loader、外部表导入导出、PL/SQL 等方式加载。如表 EXP\_CONSIGNMENT\_ORDER(源系统为 Oracle ERP)加载到临时存储区,如果源数据量小于 1G 实现代码如下:

```

procedure sp_exp_consignment_order
as
Lv_program_name varchar2(30) := 'sp_exp_consignment_order';
Lv_table_name   varchar2(32) := 'exp_consignment_order';
Lv_key_name1    varchar2(30) := 'ID';
Lv_key_name2    varchar2(30) := 'Language';
Lv_key_information varchar2(2000) := null;
Ln_key1 exp_consignment_order.id% type;
Ln_key2 exp_consignment_order. Language'% type;
Ln_ins_counter number := 0;
Ln_upd_counter number := 0;
Ld_start_date date;
Ld_end_date date;
Ln_commit_label smallint := 0; -- commit label
C_commit_rec constant smallint := 5000; -- commit rows each loop
Cursor cur_exp_consignment_order is
Select id,
       Language
       Swft_flag
       -- 省略部分列
From exp_consignment_order@tb_erp -- dblink 连接源系统
Where last_update_date >= Ld_start_date
      And last_update_date <= Ld_end_date

```

```

--- Program Start
Pkg_global.sp_exp_consignment_order(lv_program_name)
Pkg_global.sp_gb_program_date('OM', Ld_start_date, Ld_end_date);
Execute immediate 'TRUNCATE TABLE STGDM.exp_consignment_order';
For rec_exp_consignment_order in cur_exp_consignment_order
Loop
Begin
    ln_key1 := rec_exp_consignment_order.id
    ln_key2 := rec_exp_consignment_order.Language
    Insert into exp_consignment_order
        (ID, Language, source_lang --- 省略部分列)
    Values
        (rec_exp_consignment_order.id, rec_exp_consignment_order.Language)
    ln_ins_counter := ln_ins_counter + 1
    ln_commit_label := ln_commit_label + 1
End
If ln_commit_label >= C_commit_rec
Begin
    Commit;
    ln_commit_label := 0;
End if
End loop
Commit;
-- Program Complete
Pkg_global.sp_gb_program_complete(lv_program_name, ln_upd_counter, ln_ins_counter)
Exception
When others then
    --- program Error Raise
    lv_key_information := lv_table_name || ':' || lv_key_name1 || '=' || to_char(ln_key1) || ':' || lv_
    key_name2 || '=' || to_char(lv_key2);
    Pkg_global.sp_program_error_raise(lv_program_name, lv_key_information);
End sp_exp_consignment_order
    
```

加载临时存储区数据到 ODS 可参照上面从源系统到临时存储区的加载过程,主要区别是如果需要处理 Purge/Delete,应增加 Purge\_delete\_Flag 字段。

## 2. 数据转换

数据从源系统加载到临时存储区,还要经过一系列转换。Oracle 9i 内部数据转换主要采用三种方式:

- (1) 使用 SQL 进行转换。
- (2) 使用 PL/SQL 进行转换。
- (3) 使用表函数进行转换。

本例中数据转换主要采用 SQL,所以主要介绍 Oracle 9i 使用 SQL 执行合并的转换方法。在更新研发产品维表 Product\_dev\_dim 时,源系统具有和 Product\_dev\_dim 相同的结构,可通过以下代码实现。



```

Merge into product_dev_dim pdd
Using product_dev pd
On(pdd.prod_id = pd.prod_id)
When matched then
Update set
Pdd.code = pd.code ,
Pdd.name = pd.name
When not matched then
Insert
    (product_id,product_code,product_name,product_pre,effective,start_date
    ,end_date)
Values
(pd.product_id, pd.product_code, pd.product_name, product_pre, pd.effective, pd.start_date,
pd.end_date)

```

### 3. 数据清洗

本例中数据清洗依照前面数据清洗的设计方案,即:

(1) 创建清洗脚本(脚本创建在 ODS),实现代码如下:

```

CREATE TABLE CHK_RULE_DEF (
    RULE_ID          NUMBER                NOT NULL,
    RULE_REF         VARCHAR2(10),
    RULE_DESC        VARCHAR2(240),
    IS_ENABLED       CHAR(1),
    PROC_NAME        VARCHAR2(60),
    REMARK           VARCHAR2(240)
)
/
ALTER TABLE CHK_RULE_DEF
    ADD CONSTRAINT PK_CHK_RULE_MASTER PRIMARY KEY (RULE_ID)
/
/* ===== */
/* Table: CHK_TABLE_RULE_DEF */
/* ===== */
CREATE TABLE CHK_TABLE_RULE_DEF (
    TABLE_NAME      VARCHAR2(30)          NOT NULL,
    MIN_NUM_ROW      NUMBER,
    MAX_NUM_ROW      NUMBER,
    PARAMETER1       VARCHAR2(100),
    PARAMETER2       VARCHAR2(100),
    PARAMETER3       VARCHAR2(100),
    PARAMETER4       VARCHAR2(100)
)
:

```

(2) 初始化清洗元数据,实现代码如下:

```

-- DELETE DATA
delete from CHK_TABLE_RULE_DEF;

```

```

delete from CHK_RULE_DEF;
delete from CHK_REFERENCE_KEY;
delete from CHK_FIELD_RULE_DEF;

-- INSERT META DATA FOR DATA CLEARING
insert into CHK_FIELD_RULE_DEF (TABLE_NAME, FIELD_NAME, FIELD_TYPE, NULLABLE, MIN_VALUE,
MAX_VALUE, CHK_STRING, BUSINESS_KEY, PARAMETER1, PARAMETER2, PARAMETER3, PARAMETER4)
values ('ACCOUNTS', 'REFERENCE', 'C', 'N', null, null, null, 'Y', null, null, null, null);
insert into CHK_FIELD_RULE_DEF (TABLE_NAME, FIELD_NAME, FIELD_TYPE, NULLABLE, MIN_VALUE,
MAX_VALUE, CHK_STRING, BUSINESS_KEY, PARAMETER1, PARAMETER2, PARAMETER3, PARAMETER4)
values ('ACCOUNT_CONTRACTS', 'REFERENCE', 'C', 'N', null, null, null, 'Y', null, null, null,
null);
insert into CHK_FIELD_RULE_DEF (TABLE_NAME, FIELD_NAME, FIELD_TYPE, NULLABLE, MIN_VALUE,
MAX_VALUE, CHK_STRING, BUSINESS_KEY, PARAMETER1, PARAMETER2, PARAMETER3, PARAMETER4)
values ('ADDRESSES', 'REFERENCE', 'C', 'N', null, null, null, 'Y', null, null, null, null);

insert into CHK_RULE_DEF (RULE_ID, RULE_REF, RULE_DESC, IS_ENABLED, PROC_NAME, REMARK)
values (1, '', 'Check proper surrogate key(check business key)', 'N', 'PKG_SANITY_CHECK.SP_CHK
_BUSINESS_KEY', null);
insert into CHK_RULE_MASTER (RULE_ID, RULE_REF, RULE_DESC, IS_ENABLED, PROC_NAME, REMARK)
values (2, '', 'Check unique of record', 'N', 'PKG_SANITY_CHECK.SP_CHK_UNIQUENESS', null);
insert into CHK_RULE_MASTER (RULE_ID, RULE_REF, RULE_DESC, IS_ENABLED, PROC_NAME, REMARK)
:

```

(3) 执行数据清洗程序,实现代码如下:

```

CREATE OR REPLACE PACKAGE PKG_DATA_CHECK AS

PROCEDURE SP_CHK_CURRENT_IND;
PROCEDURE SP_CHK_VALID_DATE;
PROCEDURE SP_CHK_SURROGATE_KEY;
PROCEDURE SP_CHK_BUSINESS_KEY;
PROCEDURE SP_CHK_UNIQUENESS;
PROCEDURE SP_CHK_FOREIGN_KEY;
PROCEDURE SP_CHK_SKELETON_RECORD;
PROCEDURE SP_ERRM LOG(P_CHK_ID NUMBER, P_RULE_ID NUMBER, P_TABLE_NAME VARCHAR2, P_CHK_SQL
VARCHAR2, P_SQL_ERRM VARCHAR2) ;
PROCEDURE SP_CHK; -- desc: the check loop
FUNCTION F_GET_BUSINESS_KEY(P_TABLE_NAME VARCHAR2) RETURN VARCHAR2;
PKG_SDATE VARCHAR2(10) := TO_CHAR(SYSDATE, 'dd/mm/yyyy'); /* today string */
TYPE REF_CUR IS REF CURSOR; /* Ref Current Type */
REPORT_APP_ID CONSTANT VARCHAR2(20) := 'GSM'; /* application name */
DATA_SCHEMA CONSTANT VARCHAR2(30) := 'DATAPLAT'; /* the data schema */
SP_SCHEMA CONSTANT VARCHAR2(30) := 'DP_RECON'; /* the sanity check schema(not used) */
PKGB_CHECK_ID NUMBER; /* current check id */
PKGB_RULE_ID NUMBER; /* current rule id */
DEBUGING BOOLEAN := FALSE; /* debug mode True:when error accured will output error message
False: when error accured not output the error message */
END PKG_DATA_CHECK;

```



```

CREATE OR REPLACE PACKAGE BODY pkg_data_check
AS
    v_sql          LONG;
    FUNCTION f_get_business_key (p_table_name VARCHAR2)
        RETURN VARCHAR2
    IS
        v_return          VARCHAR2 (1024);

        CURSOR cur_business_key (p_table VARCHAR2)
        IS
            SELECT field_name
            FROM chk_field_rule_def
            WHERE UPPER (business_key) = 'Y'
            AND UPPER (table_name) = UPPER (p_table);
            -- v_business_key    VARCHAR2 (30);

    BEGIN
        v_return := '';
        OPEN cur_business_key (p_table_name);
        LOOP
            FETCH cur_business_key
            INTO v_business_key;
            EXIT WHEN cur_business_key % NOTFOUND;
            IF v_return != '' THEN
                v_return := v_return || '||', '||' || @TABLE. ' || v_business_key;
            ELSE
                v_return := '@TABLE. ' || v_business_key;
            END IF;
        END LOOP;
        CLOSE cur_business_key;
        RETURN v_return;
    EXCEPTION
        WHEN OTHERS THEN
            IF cur_business_key % ISOPEN THEN
                CLOSE cur_business_key;
            END IF;
            RETURN '';
    END;
:

```

#### 4. 数据装载

本例中,ETL 按照临时存储区 → ODS → 中央数据仓库 → 数据集市的流程,所有程序由 Scheduler 统一调度。以质量绩效分析为例,其装载过程包括初始装载(initial loading)和增量装载(incremental loading)两部分。初始装载相对简单,这里主要介绍增量装载,图 3.18 所示为 ADT 增量装载的完整流程。

其中:

- 1~5 步骤是增量调度程序总调度的五个阶段。
- 6、7、8、9 增量调度运行每个阶段的运行状态有四种(Q/S/C/F),其中 Q(Queued)表

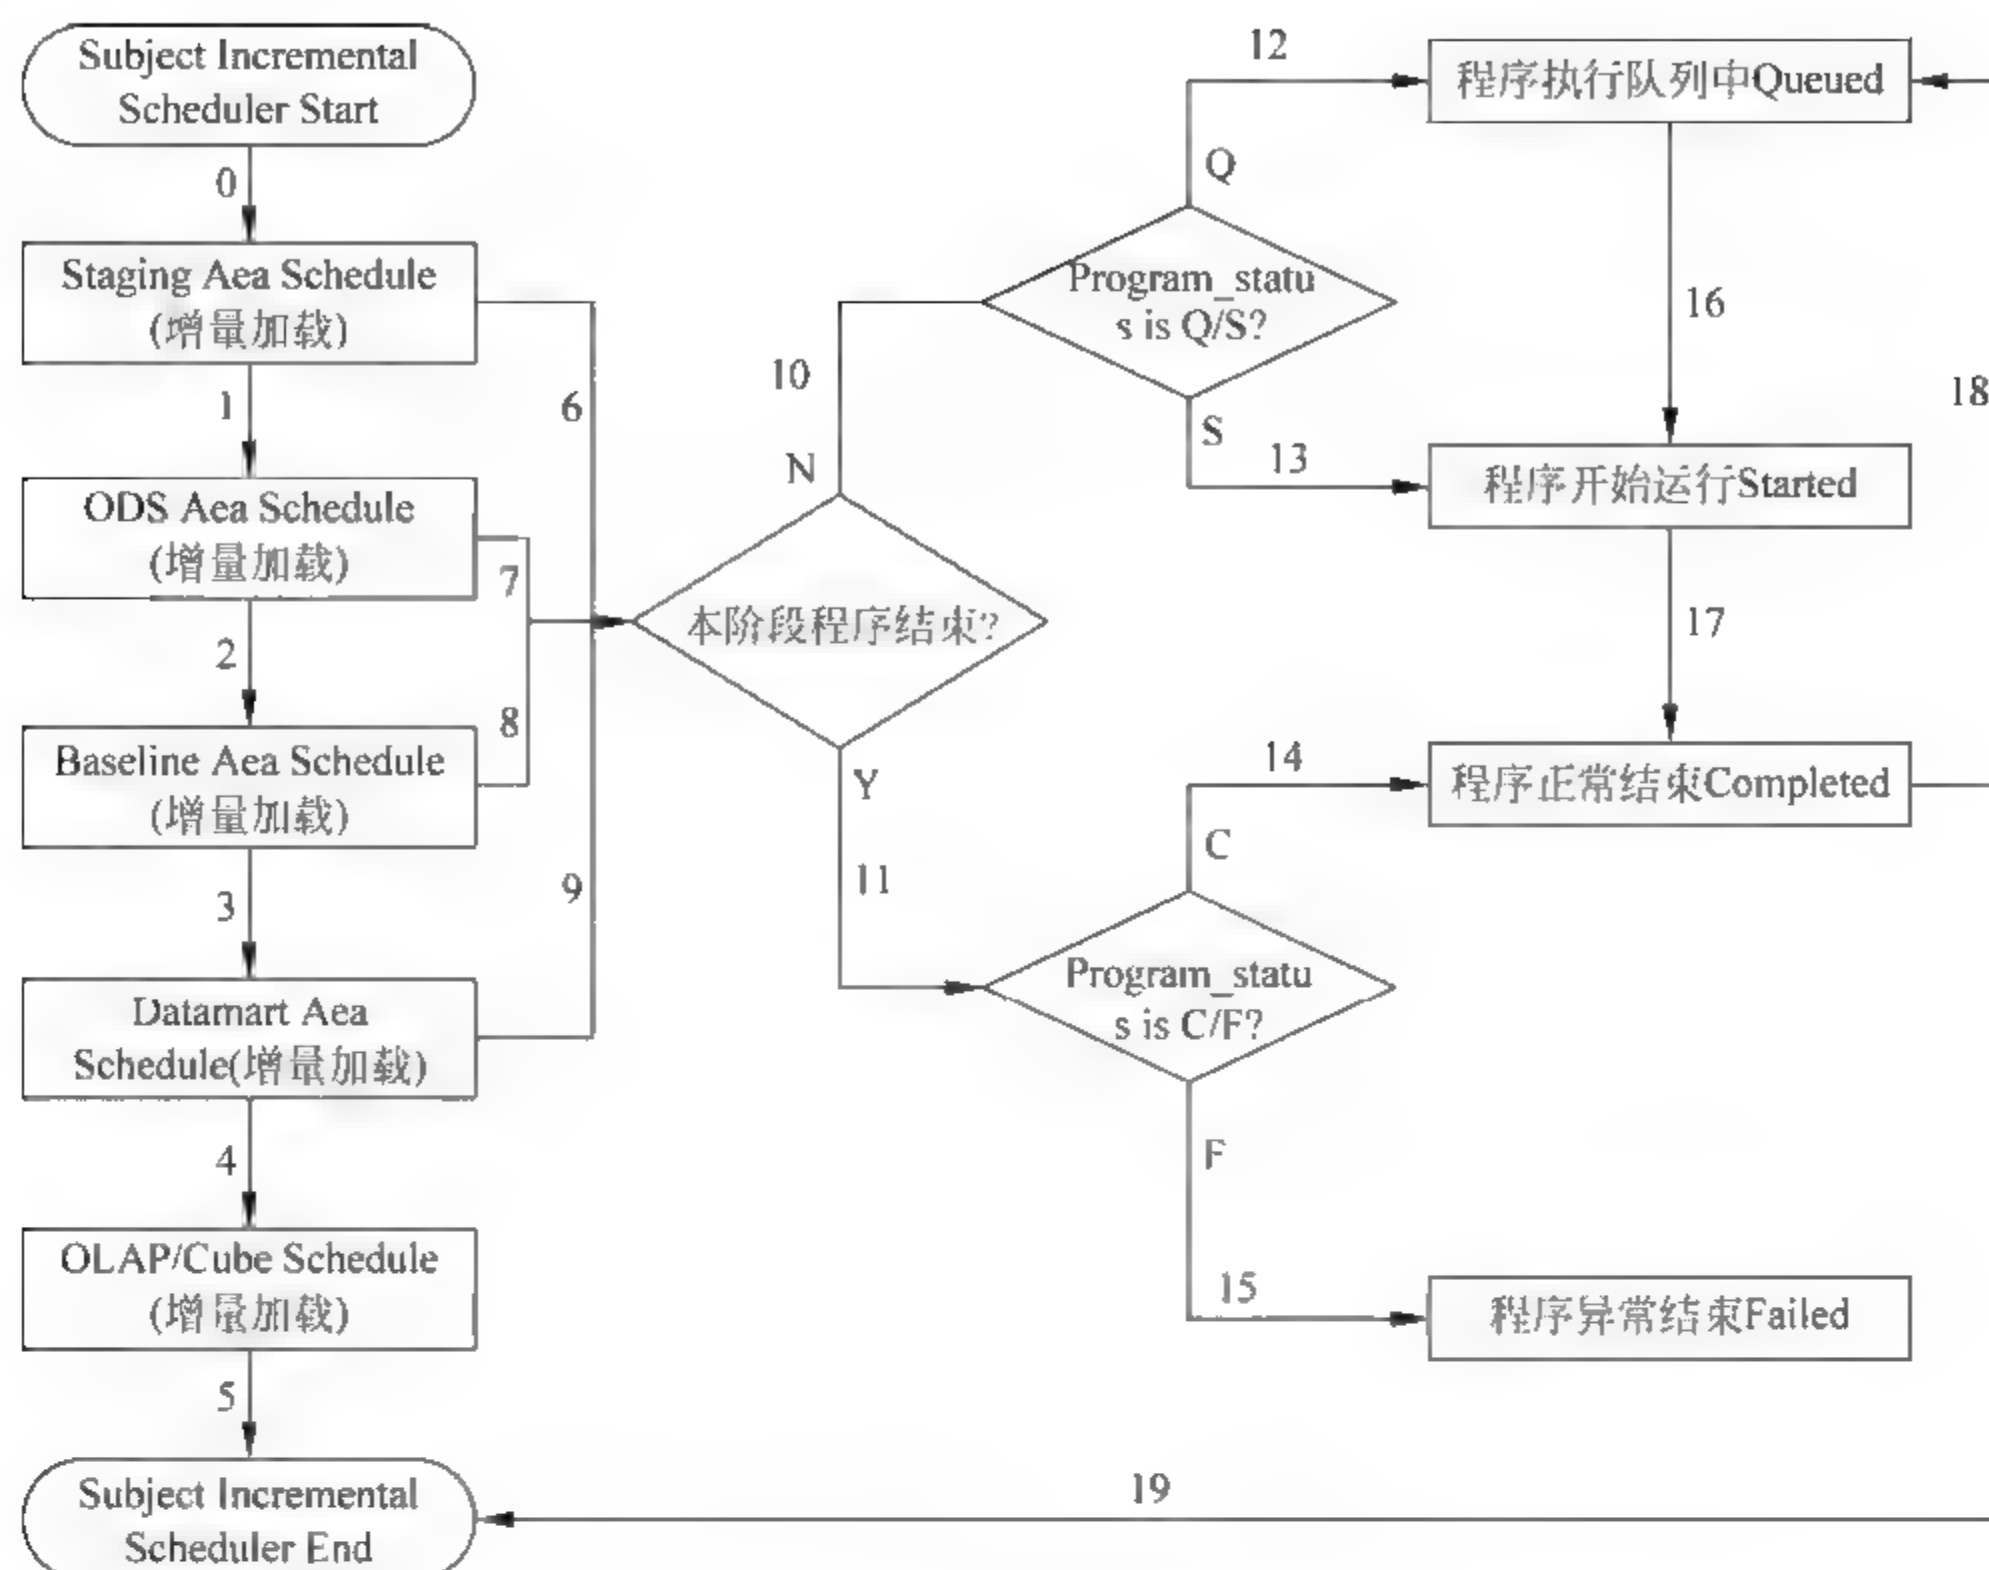


图 3.18 ADT 增量装载流程

示程序执行队列中,S(Started)表示程序开始运行,C(Completed)表示程序正常结束,F(Failed)表示程序异常结束。

- 程序运行的四种状态保存在表 program\_reference\_table 中,调度程序判断表 program\_reference\_table 中各程序的状态。
- 16: 增量调度程序被 ADT Server 调用进入队列中,program\_reference\_table 表中本程序状态为 Q。
- 17: 增量程序进入执行队列后被执行,执行中 program\_reference\_table 表中本程序状态为 S。
- 18: 增量程序执行完毕后,program\_reference\_table 表中本程序状态为 C,同时进入下一个程序的执行。
- 19: 当所有的程序执行完毕后,增量装载结束。



## 第4章 OLAP 和 OLAM

由数据仓库的定义可知数据仓库是面向决策支持的,即面向各种分析型应用的,如联机分析处理、数据挖掘、商业智能(Business Intelligence, BI)和客户关系管理等,数据仓库的数据通过 OLAP 和 DM 后,转换为信息,并最终形成知识,为科学决策提供支持。

### 4.1 OLAP

#### 1. 定义

OLAP 是基于数据仓库的一种数据分析技术,也是基于数据仓库的一种软件工具。OLAP 侧重于对决策者和高层管理人员的支持,可以根据分析人员的要求,快速、灵活地实现大量数据的复杂查询,并以一种简单、直观的形式展现查询结果。基于数据仓库实施 OLAP,可以帮助企业管理者掌握企业经营状况,了解市场需求,制定科学决策,提高企业核心竞争力。OLAP 的目标是满足决策支持或满足在多维环境下特定的查询和报表需求。

OLAP 最早是由关系数据库之父 E. F. Codd 于 1993 年提出的。当时, Codd 认为 OLTP 已不能满足终端用户对数据库查询分析的需要, SQL 对大型数据库进行的简单查询也不能满足客户深入分析的需求。客户的决策分析需要对关系数据库进行大量计算才能完成,而查询的结果并不能满足决策者的需求。因此 Codd 提出多维数据库和多维分析的概念,即 OLAP。

#### 2. 分类

根据数据存储方式的不同, OLAP 可分为 ROLAP(Relational OLAP)、MOLAP(Multi-Dimensional OLAP)和 HOLAP(Hybrid OLAP)三类。ROLAP 是指基于关系数据库的 OLAP,以关系数据库为核心,以关系型结构进行多维数据的表示和存储。ROLAP 将多维数据库的多维结构划分为两类表:一类是事实表,存储数据和维关键字;另一类是维表,即对每个维至少使用一个表来存放维的层次、成员等维的描述信息。维表和事实表通过主关键字和外关键字关联起来,形成了星型模式。对于层次复杂的维,为了避免冗余数据占用过多的存储空间,可以使用多个表描述,此时星型模式扩展为雪花型模式。MOLAP 是指基于多维数据组织的 OLAP,以多维数据组织方式为核心,即 MOLAP 使用多维数组存储数据。多维数据在存储中形成立方体结构,在 MOLAP 中对立方体的旋转、切块和切片是产生多维数据报表的主要技术。HOLAP 是指基于混合数据组织的 OLAP,如低层是关系型的,高层是多维的。这种方式具有更好的灵活性。实际上, HOLAP 是 MOLAP 和 ROLAP 的折衷。对于常用的维和维层次,在 HOLAP 中使用多维数据表记录,对于用户不常用的维和数据, HOLAP 采用类似于 ROLAP 的星型模式存储。当用户需要访问不常用的数据时, HOLAP 就会把简化的多维数据表和星型模式相拼合,从而得到完整的多维数据表。HOLAP 多维数据表中的维度少于 MOLAP 多维数据表的维度,数据存储容量也小于 MOLAP 方式。但是,在数据存取速度上 HOLAP 低于 MOLAP。HOLAP 的主要性能都



介于 MOLAP 和 ROLAP 之间,其技术复杂度高于 ROLAP 和 MOLAP。

根据数据组织方式的不同,OLAP 可分为基于多维数据库的 OLAP(MD OLAP)和基于关系数据库的 OLAP(ROLAP)两种。前者响应速度快、执行效率高,但由于结构的局限,灵活性不够。与之相比,后者建立在现有数据库(数据仓库)的基础上,灵活性、扩展性要高得多,并且支持大数据量和高维的能力也强于前者。因此,虽然在响应速度、执行效率上差一点,仍然得到广泛应用,现有的 OLAP 工具大多基于后者。

目前,针对 OLAP 的研究相当活跃,对 OLAP 的理解也不断深入。有人提出了 OLAP 更为简洁的定义,如 Nigel Pendse 提出的 FASMI(Fast Analysis of Shared Multidimensional Information),所采用的技术包括客户/服务器结构、时间序列分析模型、并行处理、面向对象、数据存储和多线程技术等。

### 3. 典型操作

OLAP 对数据仓库数据的操作基于多维视图(或称立方体)。对立方体的典型操作包括切片、切块和旋转等,如图 4.1 所示。




图 4.1 立方体的典型操作

- 切片是指选定多维数组的一个二维子集。
- 切块是指选定多维数组的一个三维子集。
- 旋转是指改变一个立方体显示的维方向,使人们可以从不同的角度更加清晰、直观地观察数据。

此外还包括一些其他操作,例如:

- 上卷是指沿某一个维的概念分层向上归约,并且通过维归约,在立方体上进行聚集。
- 下钻是上卷操作的逆操作,由不太详细的数据到更详细的数据。
- 钻取是指对多个事实表进行查询。
- 钻透是指对立方体操作时,利用数据库关系,钻透立方体的底层,进入后端的关系表。

### 4. 主要特点

OLAP 是数据仓库的分析展示工具,建立在数据多维视图的基础上。主要特点一是在线(Online),体现为对用户请求的快速响应和交互式操作;二是多维分析,这也是 OLAP 技术的核心所在。

OLAP 主要通过多维方式实现数据分析、查询和报表,不同于传统的 OLTP。首先,



OLTP 主要面向公司员工,OLAP 则主要面向公司领导层;其次,OLTP 主要完成用户的事务处理,其数据基础是操作型数据库,如民航订票系统、银行储蓄系统等,通常需要进行大量的更新操作,同时对响应时间要求较高。而 OLAP 是以数据仓库或数据多维视图为基础的数据分析处理,是针对特定问题的联机数据访问和分析,一般不进行数据修改只是查询,其应用主要是分析客户的当前及历史数据以辅助决策,典型的应用包括对银行信用卡风险的分析与预测、公司市场营销策略的制定等,主要是进行大量的查询操作,对响应时间的要求不太严格。

### 5. 实现途径

OLAP 实现通常采用三层客户/服务器(Client/Server,C/S)结构。第一层是数据仓库服务器,实现与基层运营的数据库系统的连接,完成数据的一致性和共享;第二层是 OLAP 服务器,根据最终服务请求分解成 OLAP 的各种操作,并使用数据仓库中的数据完成这些操作;第三层是前端展现工具,用于将 OLAP 服务器的处理结果以直观的方式,如多维报表、饼图和三维图等展现给最终用户。

### 6. 评价标准

1993 年,E. F. Codd 提出了关于 OLAP 的 12 条评价标准,旨在加深对 OLAP 的理解,后来扩充到 18 条。对于设计数据仓库以及使用 OLAP 的用户而言,理解这些标准是十分必要的。

18 条准则具体如下:

- 准则 1 多维性,能对多维数据进行切片、切块和旋转等操作。
- 准则 2 直观性,能为用户提供直观、易用的数据操作。
- 准则 3 可访问性,OLAP 以合适的方式存储数据,便于用户访问。
- 准则 4 解释性批处理,在 OLAP 中常由 OLAP 引擎或服务器上存储立方体的混合工具实现。
- 准则 5 OLAP 分析模型,在高层获取 OLAP 所支持的分析数据,包括静态描述性报告、解释性分析、假设性分析和预测性分析等。
- 准则 6 客户-服务器结构性,用户通过客户端与服务器的松散耦合实现 OLAP。
- 准则 7 透明性或开放性,OLAP 及其数据源对用户的透明和开放。
- 准则 8 多用户性,要求 OLAP 在实际应用中保证数据的完整性和安全性,并能够进行数据的并发处理。
- 准则 9 处理非正规数据,要求系统满足“强聚合,弱耦合”的标准。
- 准则 10 存储 OLAP 结果,要求将决策分析和数据源分开。
- 准则 11 提取丢失值,是系统处理空值的一种方式。
- 准则 12 处理丢失值,要求 OLAP 引擎忽略已经提取的丢失值。
- 准则 13 弹性报告,要充分反映数据的多维特征,具有较强的灵活性。
- 准则 14 一致性报告,即要求 OLAP 能够为用户提供时间可预计的报告。
- 准则 15 对物理层的自动调整,其为关系模型的标准。
- 准则 16 通用维,即在结构和操作能力方面完全一致的维。
- 准则 17 无限维与聚合层,OLAP 维数不应该小于 15,且在任意路径建立任意多个聚合层次,给定路径的概括级数据也是有限的。



**准则 18 无限制跨维操作**,要求能够在维之间进行符号操作,而不仅仅是对可测量数据的操作。

上述评价标准仍存在较大争议,例如第 16 条除了时间维,多数维都有自己的特性;而第 17 条在现实中很难实现,否则会导致数据在有限空间内急剧膨胀。

## 7. 主流工具

目前,市场上主流的 OLAP 及前端展现产品几乎都是在 1993 年之前出现的,有的甚至已有三十多年的历史,如 Cognos (PowerCenter)、Hyperion (Essbase)、微软 (Analysis Service)、Business Object 以及 MicroStrategy 等几大厂商的产品。

综合业界多方面观点,在此将对 Cognos、Hyperion 和 Business Object 这三家厂商的产品在整体解决方案、OLAP 工具、系统稳定性以及集成等方面进行综合比较。

### 1) Cognos 8

Cognos 8 解决方案在一个产品中,一种 Web 构架下,基于企业所有数据源,面向所有用户提供完整的信息处理与展现功能,包括了即席分析功能、查询功能、报表功能、仪表盘功能、事件管理功能以及 BI 管理功能等。Cognos 8 采用 SOA (Service Oriented Architecture,面向服务的体系结构),统一了 Web 应用构架和元数据,能够访问企业的所有数据源,为企业所有用户提供了基于纯浏览器的、全面的 BI 功能。

- **前端产品** 主要包括 Report Studio, Analysis Studio 以及 Query Studio 等。
- **OLAP 工具** Cognos PowerPlay 以桌面 OLAP 开始,一直以轻便、快捷的操作闻名,虽然 PowerPlay 早已演变成 C/S 结构的 OLAP 服务器,但其轻便的特点仍在延续,而且提供可以简洁部署且具有交互性的 Framework Manager 界面。
- **优点** 易于集成、部署和使用,经过简单培训后就能进行设计与开发。
- **缺点** 目前国内没有分公司,只有国家信息中心下属的优信佳公司独家代理,其服务能力有限。

### 2) Hyperion System 9

Hyperion System 9 BI+ 实现 BI 标准化策略的方法是采用统一系统满足多种多样的报表和分析需求,即企业内每个部门的每位用户,都能通过易于操作和维护的统一系统按需生成报表或进行分析。这样,企业内的信息使用者和生产者就获得了快速生成、访问和共享重要信息的便利,增强了工作的灵活性,而他们也需要这些重要信息来更快、更好地做出业务决策。简单而功能强大的用户界面使业务用户在自行创建报表时对 IT 支持和依赖降到了最低。产品模块化的架构极大地降低了用户对 IT 支持的需求,通过 Hyperion System 9 BI+ 平台,用户只需在服务端部署和管理即可。

- **前端产品** 主要包括 BI+ Web Analysis 和 BI+ Interactive Reporting。
- **OLAP 工具** Essbase 作为老牌的 OLAP 服务器是一个比较复杂的产品,所谓复杂有两层含义,一是提供丰富的 API,允许充分定制开发;二是开发的难度较大,不易部署。虽然其产品性能很高,但即使厂商的技术人员也很难掌握其烦琐的技术细节。
- **优点** BI+ Web Analysis 查询灵活,不需编程,适合业务人员使用。BI+ Interactive Reporting 适合复杂查询和报表设计,结合 Essbase 性能较快。
- **缺点** 安装配置非常麻烦,使用 BI+ Interactive Reporting 必须会 JSP 语言,操作性



较差,各种图形饱和度差些。

### 3) Business Object

BO是集查询、报表和OLAP展现为一身的智能决策支持工具,它使用独特的语义层和动态微立方等技术表示数据库中的多维数据,具有较好的查询和报表功能,提供钻取等多维分析技术,支持多种数据库,同时还支持基于Web浏览器的查询、报表和分析决策。

- **前端产品** 主要包括 Web Intelligence 和 Crystal Reporting(水晶报表),还有仪表板和绩效管理工具。
- **OLAP 工具** 虽然 BO 在不断增加新的功能,但严格地讲,只能算是一种前端工具。也许正因为如此,几乎所有的数据仓库解决方案都把 BO 作为可选的数据展现工具。
- **优点** 用户界面美观,图形饱和度高,拥有多种新颖仪表板和记分卡。
- **缺点** 不能出现网络中断,否则需要重启。程序安装后不能删除,否则会造成系统崩溃,仪表板之间的集成度稍差些。报表和分析工具较复杂,用户很难自行设计所需的报表,开发与维护成本较高。

## 4.2 OLAM

数据挖掘与OLAP不同,主要体现在其分析数据的深入和分析过程的自动化,自动化的含义是指分析过程不需要用户参与。这是一把双刃剑,在实际中,用户也希望参与到挖掘中,如仅对数据的某一子集进行挖掘,以及对不同抽取、集成水平的数据进行挖掘,还有希望根据自己的需要动态选择挖掘算法等等。可见,OLAP与数据挖掘各有所长,如果能将二者结合衍生出一种为数据挖掘服务的具有新型OLAP功能的应用,将更能适应实际的需求,联机分析挖掘(OnLine Analytical Mining,OLAM)正是这种结合的产物。

1997年Han J. W.提出了OLAM的概念,将OLAM定义为OLAP Mining,其含义是将OLAP和数据挖掘技术结合起来,在多维模型即数据立方体的基础上对外提供数据分析和知识发现应用,即在OLAP基础上,对数据分析算法进行扩充,把数据挖掘算法引入到多维模型的数据环境中,并把这种思想在其研制的DB Miner系统中加以实现。

Han J. W.提出的OLAM的研究方向是数据分析算法和数据挖掘算法如何与数据立方体高效地结合,解决多维数据环境的数据挖掘。但是对于如何在系统体系结构上将OLAP和数据挖掘有机地结合起来,即在异构、海量的环境中快速响应用户的数据分析和数据挖掘请求的问题没有做深入研究。

就OLAP和数据挖掘技术结合的系统集成度而言,可分为松散的集成和紧密的集成两种,即:

- (1) 松散的集成是指系统的集成度不高,即把分立的OLAP系统和数据挖掘系统组合在一起,两者没有统一的逻辑模型和任/事务模型。
- (2) 紧密的集成是指系统采用统一的逻辑模型、任/事务模型、数据定义语言和数据操作原语,对于数据密集和耗时较多的操作,系统进行统一的调度和优化,从而在系统内核上将OLAP和数据挖掘有机结合在一起。

Han J. W.提出的OLAM以及其实现的DB Miner系统是一种松散的集成。其实,早



在 OLAM 概念之前,在数据挖掘领域已有将 OLAP 与数据挖掘结合起来提供更优质的数据分析和决策支持工具的思路。有许多 OLAP 产品在功能上添加了数据挖掘能力,在具体实现方式上可以分为两类:

(1) 在现有 OLAP 产品基础上,通过系统的改造增加数据挖掘功能,如 Business Object 产品中的决策树分析、DB Miner 系统中的数据挖掘算法工具箱。在这种实现方式中 OLAP 与数据挖掘的结合松散,拼装的痕迹明显,对系统整体体系结构的考虑较少,不能同时充分发挥两者的优势。

(2) 把数据挖掘算法集成在系统的底层功能中,OLAP 与数据挖掘结合紧密,Microsoft 公司的 SQL Server 2000 中的关联分析方法在数据库端的集成就是紧密集成这种方式的初步尝试。

推动 OLAM 发展的原始驱动力主要体现在:

(1) 分析需要的数据是一些经过净化、集成处理的数据,通常这种处理过程也是昂贵的。而数据仓库作为 OLAP 的数据源,存储的就是这样的数据。它能为 OLAP 提供数据,当然也可以为数据挖掘提供数据。

(2) 数据仓库是一项崭新的技术,很多人在研究它,围绕着它有许多工具或是体系结构。而数据挖掘作为数据分析工具的一种,不是孤立的,必然与其他工具发生联系。因此,考虑到如何最大限度地利用这些现成的工具,也是 OLAM 发展之初所关心的问题。

(3) 成功的数据挖掘需要对数据进行钻探性分析。例如,挖掘所需的数据可能只是一部分、一定范围的数据。因此,对多维数据模型的切片、切块和下钻等操作,同样可以应用于数据挖掘中。换言之,可以将数据挖掘建立在多维模型基础上。

(4) 用户参与对数据挖掘的重要性。动态地提出挖掘要求、选择挖掘算法,因此可以将 OLAP 的 C/S 结构应用于数据挖掘。

#### 4.2.1 体系结构

OLAM 的挖掘分析是建立在数据仓库基础上的,数据挖掘所需要的数据在进行挖掘之前已经过预处理并存放在数据仓库中,这在很大程度上提高了数据挖掘的响应速度。

此外,具体的数据挖掘算法与数据源之间的关系完全透明。用户在进行挖掘时,首先根据算法要求从数据仓库中提取相关数据,然后进行运算,挖掘产生的结果即学习获得的知识,则写回到数据仓库的相应库表中,以立方体的形式展现给用户,如图 4.2 所示。

这里有两个问题需要详细讨论,即:

(1) 算法选择问题。如前所述,OLAM 发展的源动力之一是给予用户一定算法选择的灵活性。因为对于同一个功能一般可以采用多种算法实现,例如分类可以是基于统计学,或基于机器学习或基于神经网络。不同的算法针对不同的问题空间有不同的性能,如何选择最高性能的算法,是用户需要考虑的问题。另一方面,OLAM 的最终用户往往对具体算法并不了解,因此提供太大的灵活度反而让用户无所适从。实际的做法是针对 OLAM 具体的问题空间,在充分实验的基础上,仅提供有限的几种算法参与知识发现过程,并将结果反馈给用户,让用户选择最贴近实际的结果。这在一定程度上避免了用户与挖掘算法的直接接触。



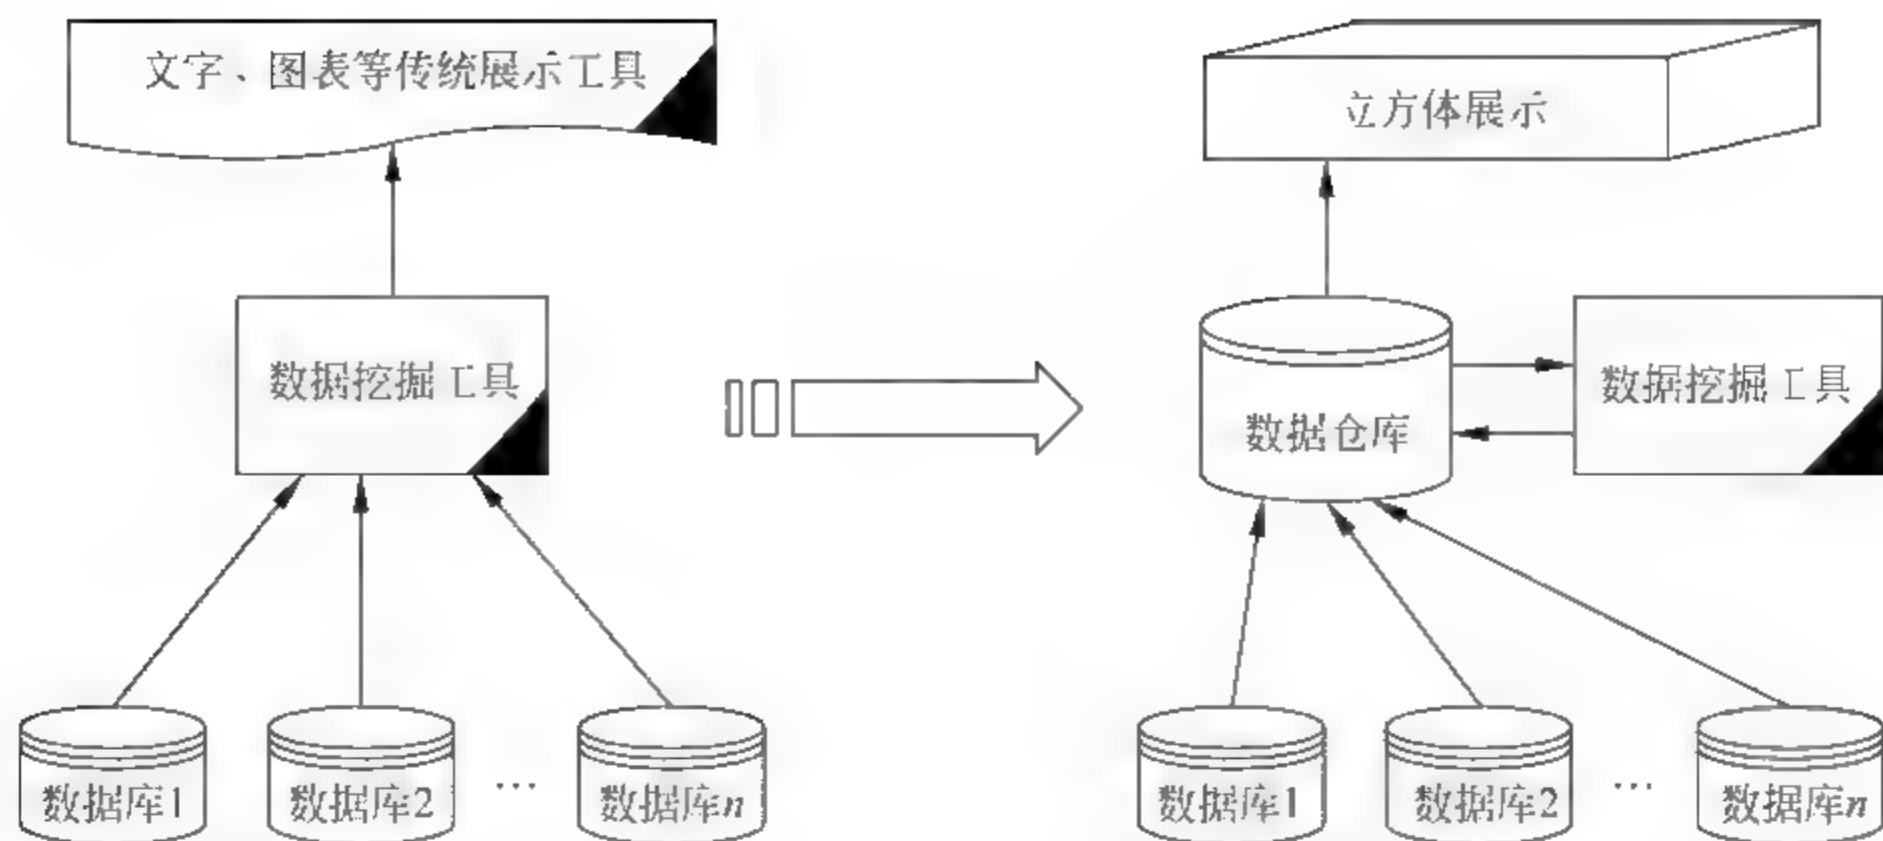


图 4.2 OLAM 结构演变示意图

(2) 源数据钻探问题。我们知道,传统的数据挖掘建立在各种数据源之上,在挖掘之前,往往需要花费大量的时间进行数据预处理,这大大降低了系统的响应性能。而 OLAM 建立在数据仓库之上,挖掘所需的源数据事先已存放在数据仓库中。然而,有些挖掘算法往往需要底层的详细数据,如分析电信客户行为时需要客户的通话详单,这些数据一般数据量巨大且更新频繁,不可能将其全部复制到数据仓库中。一是因为系统容量有限,二是由于系统不堪频繁数据更新的重负。实际上,还是将这样的数据存放在各个事务数据库中,如前所述数据仓库在物理上也可能就是原来的事务数据库。因此,这些在实际中根据需要存储分析或挖掘所需数据的事务数据库,在逻辑上构成了一个虚拟数据仓库,如图 4.3 所示。

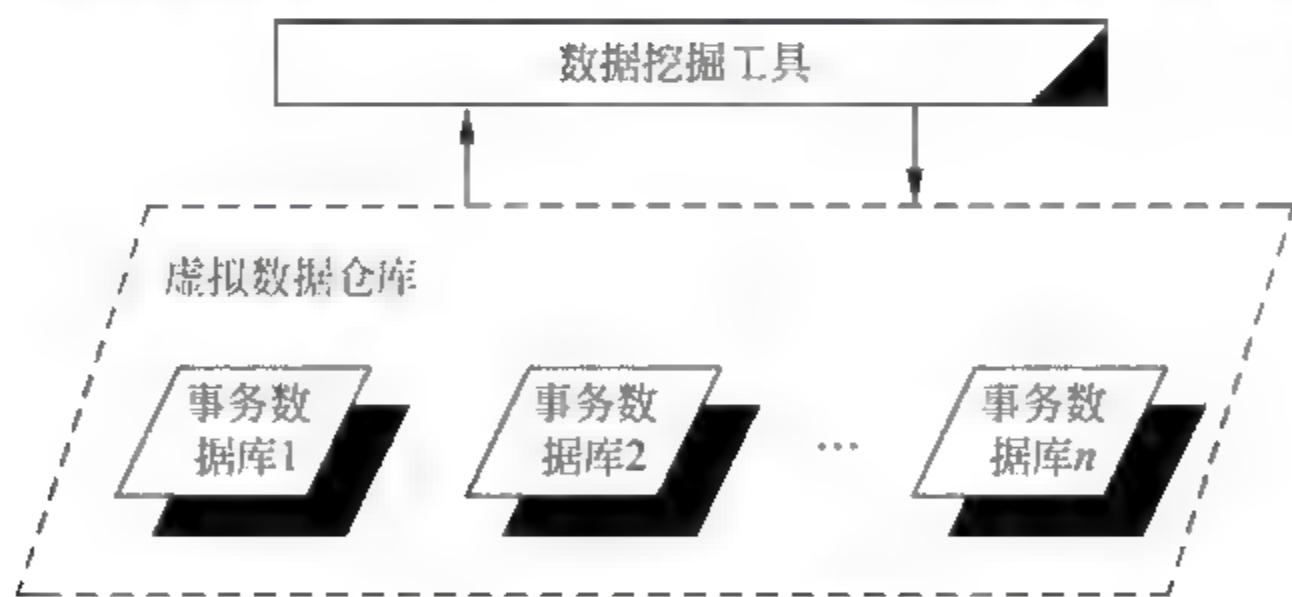


图 4.3 虚拟数据仓库示意图

OLAM 的挖掘分析是建立在多维模型基础上,而且在实际应用中,尽管 OLAM 的多维计算可能需要更多的维度和更强大的访问工具。但是 OLAP 的立方体和 OLAM 的立方体之间并没有本质区别。

#### 4.2.2 特点

建立在庞大数据库或数据仓库基础上的 OLAM 在实现过程中面临的最大挑战是执行效率的提高和对用户请求的快速响应。目前还没有 OLAM 产品出现,对 OLAM 应具备的特点也众说纷纭。但是,针对 OLAM 的基本结构做到以下几点是必要的。



(1) OLAM 建立在多维数据库和 OLAP 的基础上,因此应能方便地对任何数据或不同抽象级别的数据进行挖掘。这是借助 OLAP 对超级立方体进行切片、切块和下钻等操作实现的。另外,如果需要 OLAM 还可以直接访问存储在底层数据库中的数据。总之,借助于 OLAP 的支持,OLAM 能对任何数据进行挖掘。

(2) 用户对挖掘算法具有动态选择的权力,在传统的关系数据库中,对同一个主题,任何不同的查询过程所得到结果是相同的。而数据挖掘则不然,对同一个问题,运用不同的挖掘算法,获得的结果可能大相径庭。因此有必要给予用户以动态选择挖掘算法的权力。此外,有些用户针对自己的问题,可能有一套独特的挖掘算法,并希望嵌入到 OLAM 中。因此,OLAM 应该具有通用接口,便于与其他工具或算法相衔接。

(3) OLAM 建立在多维数据视图的基础上,因此基于超立方体的挖掘算法是其核心。超立方体计算与传统挖掘算法的结合使得数据挖掘有了极大的灵活性和交互性。这里所说的超立方体计算一般是指切片、切块、下钻和旋转等操作。而传统挖掘算法是指关联、分类、聚类和预测等基于关系型或事务型的挖掘算法。根据超立方体计算和数据挖掘所进行的次序的不同组合可以有以下几种模式,即:

- 先进行立方体计算,后进行数据挖掘。在进行数据挖掘前,先对多维数据进行一定的立方体计算,以选择合适的数据范围和恰当的抽象级别。
- 先对多维数据进行挖掘,然后再利用立方体计算对挖掘结果做进一步的深入分析。
- 立方体计算与数据挖掘同时进行,在挖掘的过程中可以根据需要对数据视图进行相应的多维操作,这意味着同一个挖掘算法可以应用于多维数据视图的不同部分。

(4) 回溯和书签功能。OLAM 的挖掘过程是对多维数据视图的一个不断深入的过程。实际中,用户很有可能因为算法的复杂而在超立方体中“迷失方向”。因此 OLAM 的挖掘算法应能给用户提供了上次操作、初始状态的回溯及书签功能。

(5) 与 OLAP 类似,OLAM 也采用 C/S 架构,这使得其具有较高的执行效率和较快的响应速度。但由于一般挖掘算法都复杂且耗时,因此在执行效率和挖掘准确性两者之间需要进行权衡。一般情况下,OLAM 与用户频繁且高速地交互,应选择合适的挖掘算法和数据空间,一旦这两点确定,在特定数据空间上再执行用户选定的复杂挖掘算法,以保证最终结果的正确性。

此外,OLAM 还应具有灵活的可视化工具和良好的扩展性。OLAM 的结构复杂,在实际应用中要与多个模块或工具交互作用。例如,OLAM 可能与一个统计软件包相结合,或者系统本身功能扩展使之适合于地理数据、文本数据或商业数据的挖掘。因此,OLAM 接口的标准化和通用性则显得尤为重要。OLAM 是 OLAP 与数据挖掘相结合的产物,它兼具 OLAP 多维分析的在线性、灵活性和数据挖掘对数据处理的深入性,是具有数据挖掘功能的数据仓库,也是数据仓库应用工具未来发展的方向。

#### 4.2.3 基于 Web 的 OLAM

基于 C/S 架构的 OLAP、OLAM 的一个重要特点是与用户的交互性。WWW 也是基于这样的模式。此外,由于用户前端展示工具的一致性(各种浏览器),使其具有更大的开放



性。基于 Web 的 OLAM 是 Web 技术与 OLAP 和 OLAM 的结合,也是 Web 数据库下一步发展的目标。

可以把基于 Web 的 OLAM 看做是能提供多维分析和挖掘功能的 Web 数据库应用。OLAM 以应用程序服务器的形式连接到网络,浏览器端的用户可以通过 Web 服务器访问 OLAM 服务器。

如图 4.4 所示,WWW 服务器是实现 OLAM 功能的中枢,其执行流程的大致步骤如下:

- ① 浏览器端用户通过 HTML 文件中的表单提出数据分析和挖掘请求并传递给 WWW 服务器。
- ② WWW 服务器端调用相应的应用程序如 CGI、ISAPI、NSAPI 等,并根据需要激活 OLAM 服务程序。
- ③ OLAM 服务器引擎将立方体操作转换为 SQL 请求,并交付 DBMS/DWMS 执行。
- ④ WWW 服务器将结果反馈给用户。

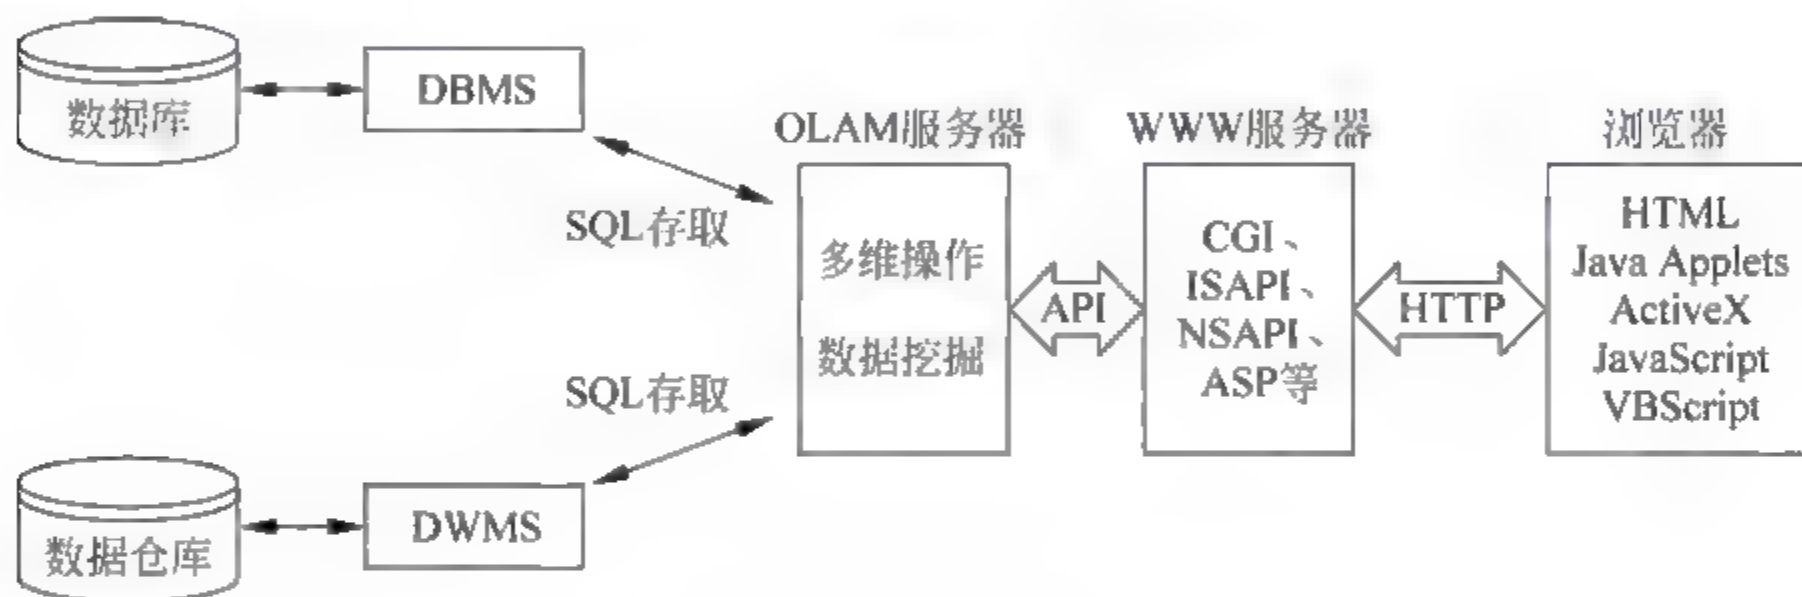


图 4.4 基于 Web 的 OLAM 结构框图

实现交互式的数据库应用系统,在服务器端一般是执行相应的 CGI 或 ISAPI 程序,但开发 CGI 和 ISAPI 复杂而低效,并且对程序员要求也较高。目前较为先进的是采用 ASP (Active Server Pages) 技术。另外,考虑到最大限度地减少通信量及增加灵活性,在浏览器端引入了 Java Applets、ActiveX 或 VBScript 等组件。

目前,基于 Web 的 OLAM 应用还处于起步阶段,这一领域的很多问题有待研究。例如:

(1) Web 数据以多种形式存在,一般是超文本文件,而且结构性较差。迄今为止,Internet 的信息描述语言已由最初的 SGML、HTML 发展到现在的 XML 和 DHTML。但是,由于浏览器的不同,很难在各种语言的解释执行方式上取得一致。因此,数据描述语言的标准化显得尤为重要。

(2) 基于 Web 的 OLAM 前端展示工具。浏览器虽然具有界面统一、易于操作等特点,但仅限于提供交互式操作,很难构造复杂应用。因此,能否开发一种接近人类自然语言的 Web 查询语言,成为研究热点之一。

(3) 系统执行效率和响应速度是用户最关心的问题,也是基于 Web 的 OLAM 在实际中遇到的最大挑战。影响这一性能的主要因素,一是物理网络的传输速度;二是服务器端的分析挖掘算法的执行效率。随着网络技术的发展,前者已逐渐不足为虑,而后者因为大部

分多维分析算法,如对超立方体的切片、切块、旋转等操作以及各种数据挖掘算法都是复杂而耗时的,因此对 OLAM 服务器提出了很高、有时甚至是很难满足的要求。

此外,还有一些非技术因素也是基于 Web 的 OLAM 在今后的发展中需要认真解决的问题,如信息安全性、保密性以及版权和收费问题等。

除了 OLAP 和 OLAM 之外,数据挖掘也是数据仓库的一个重要应用。后面将加以详细介绍。



## 第 二 篇

# 数 据 挖 掘

- 第5章 数据挖掘基础
- 第6章 聚类分析
- 第7章 分类和预测
- 第8章 关联分析
- 第9章 Web挖掘
- 第10章 数据挖掘实例





## 第5章 数据挖掘基础

20 世纪末,随着 Internet 的普及,全球信息量以惊人的速度急剧增长,据估计每二十个月就增加一倍。许多组织机构的 IT 系统都存储了大量数据。目前的数据(仓)库系统虽然可以高效地实现数据的录入、查询和统计等功能,但却无法发现海量数据中隐藏的关系和规则,无法预测未来的发展趋势。为了充分利用资源,从海量数据中发现隐藏的知识和规律,数据挖掘应运而生并显示出极其强大的生命力。

数据挖掘作为一门新兴的交叉学科,涉及数据库、数据仓库、统计学、机器学习、可视化、信息检索和高性能计算等诸多领域,其他相关的领域还包括人工智能(Artificial Intelligence, AI)、模式识别、空间数据分析、图像处理、概率论、图论和归纳逻辑等。

### 5.1 概述

数据挖掘的提出是在 20 世纪 80 年代,它是一个新兴的、面向商业应用的 AI 研究领域。

1989 年 8 月,在美国底特律召开的第 11 届国际人工智能联合会议的专题讨论会上首次出现数据库中的知识发现(Knowledge Discovery in Database, KDD)这一术语。随后,在 1991 年、1993 年和 1994 年都举行了 KDD 专题讨论会,汇集来自各个领域的研究人员和应用开发者,集中讨论数据统计、海量数据分析算法、知识表示和运用等问题。最初,数据挖掘是作为 KDD 中利用算法处理数据的一个步骤,后来逐渐演变成 KDD 的同义词。

KDD 常常被称为数据挖掘,实际上两者是有区别的。一般将 KDD 中进行知识学习的阶段称为数据挖掘。数据挖掘是 KDD 中一个非常重要的处理步骤。但是,人们往往不加区别地使用。

数据挖掘是近年来出现的客户关系管理、商业智能等热点领域的核心技术之一。

#### 5.1.1 定义

从技术角度而言,数据挖掘是从大量的、不完全的、有噪声的、模糊的、随机的实际数据中,提取隐含在其中人们事先不知道但又是潜在有用的信息和知识的过程。这一定义包括多层含义,即数据源必须是真实的、海量的、有噪声的,发现的知识应是用户感兴趣的,并且是可接受、可理解和可运用的,并不要求是放之四海而皆准的知识,可以仅支持特定的问题。

从商业角度而言,数据挖掘是一种新的商业信息处理技术,其主要特点是对数据库中的大量业务数据进行抽取、转换、分析和其他模型化处理,从中提取辅助商业决策的关键性信息和知识。

简言之,数据挖掘本质上是一种深层次的数据分析方法。因此,数据挖掘可以描述为按企业既定业务目标,对大量的企业数据进行探索和分析,揭示隐藏的、未知的或验证已知的规律性,并进一步将其模型化的有效方法。



数据挖掘所发现的最常见的知识包括:

### 1. 广义(generalization)知识

广义知识是类别特征的概括性描述知识。根据数据的微观特性发现其表征的、带有普遍性的、较高层次概念的、中观和宏观的知识,反映同类事物的共同性质,它是对数据的概括、精炼和抽象。

广义知识的发现方法和实现技术有多种,如数据立方体、面向属性的归约等。其中,数据立方体的基本思想是实现某些常用的代价较高的聚集函数的计算,如求和、平均值和最大值等,并将其存储在多维数据库中。因为很多聚集函数都需要重复计算,在多维数据立方体中存放预先计算好的结果将保证快速的响应,并灵活地提供不同角度和抽象层次上的数据视图;另一种广义知识的发现方法是加拿大 Simon Fraser 大学提出的面向属性的归约方法。该方法以类 SQL 语言表示数据挖掘查询,收集数据库中的相关数据集,然后应用一系列数据分析技术,包括属性删除、概念树提升、属性阈值控制及其他聚集函数计算等。

### 2. 关联(association)知识

关联知识是反映一个事件和其他事件之间依赖或关联的知识。如果两项或多项属性之间存在关联,则其中的一项就可以依据其他属性值进行预测。最著名的关联分析算法是 R. Agrawal 提出的 Apriori。关联分析的实现步骤是第一步通过迭代识别所有的频繁项集,要求频繁项集的支持率不低于用户设定的阈值;第二步从频繁项集中构造可信度不低于用户设定的阈值的规则。该算法的核心是识别或发现所有频繁项集,这也是计算量最大的部分。

### 3. 分类(classification & clustering)知识

分类知识是反映同类事物共同性质的特征知识和不同事物之间的差异性的特征知识。最典型的分类方法是基于决策树的分类,它从实例集中构造决策树,是一种有监督和指导的学习方法。该方法先根据训练集(又称为窗口)形成决策树。如果该决策树不能对所有样本给出正确的分类,则选择一些例子加入到窗口中,重复该过程直到形成正确的决策集,即一棵决策树,其叶结点是类名,中间结点是带有分支的属性,分支对应该属性的某一可能值。最经典的是 ID3 算法,采用自顶向下不回溯策略,保证找到一棵简单的决策树。C4.5 和 C5.0 等算法都是 ID3 的扩展,将分类从类别属性扩展到数值型属性。

此外,还有统计、粗糙集(rough set)和神经网络等分类方法。

### 4. 预测(prediction)知识

预测知识根据时间序列,由历史的和当前的数据预测未来,也可以认为是以时间为关键属性的关联知识。

目前,时间序列预测的主要方法包括统计、神经网络和机器学习等。1968 年 Box 和 Jenkins 提出了一套比较完善的时间序列建模理论和分析方法,通过建立随机模型,如自回归模型、自回归滑动平均模型、求和自回归滑动平均模型和季节调整模型等,实现时间序列预测。由于大量的时间序列是非平稳的,其特征参数和数据分布随着时间的推移而发生变化。因此,仅仅通过对某段历史数据的训练,建立单一的预测模型,还无法准确地预测。为此,人们提出了基于统计学和精确性的再训练方法,当发现现有预测模型不再适用于当前数据时,对模型重新训练,获得新的参数,建立新的模型。也有许多系统借助并行算法实现时间序列预测。



### 5. 偏差(deviation)型知识

偏差型知识是对差异和极端特例的描述,揭示事物偏离常规的异常现象,如标准类外的特例,数据聚类外的孤立点(outlier)等。

上述知识都可以在不同的概念层次上被发现,并随着概念层次的提升,从微观到中观再到宏观,以满足不同用户不同层次的决策需要。

数据挖掘的演化过程如表 5.1 所示。

表 5.1 数据挖掘的演化过程

进化阶段	商业问题	支持技术	产品厂家	产品特点
数据搜集 (20 世纪 60 年代)	“过去五年中我的总收入是多少?”	计算机、磁带和磁盘	IBM、CDC	提供历史、静态的数据
数据访问 (20 世纪 80 年代)	“在新英格兰的分部去年三月份的销售额是多少?”	关系数据库(RDBMS),结构化查询语言(SQL)	Oracle, Sybase, IBM, Microsoft	提供记录级的历史、动态的数据
数据仓库、决策支持 (20 世纪 90 年代)	“在新英格兰的分部去年三月份的销售额是多少? 波士顿据此可得出什么结论?”	联机分析处理(OLAP)、多维数据库、数据仓库	Pilot、Comshare、Arbor、Cognos 和 Microstrategy 等	在各种层次上提供回溯、动态的数据
数据挖掘	“下个月波士顿的销售趋势如何? 为什么?”	数据挖掘算法、多处理器计算机、海量数据仓库	Pilot、Lockheed、IBM、SGI 等	提供预测性信息

在了解数据挖掘演化过程的基础上,以下两个问题值得探讨。

#### 1) 数据挖掘与统计学的关系

近年来,人们逐渐发现数据挖掘的许多工作都是利用统计方法实现的。一些人(尤其是统计学家)甚至认为数据挖掘是统计学的一个分支,当然大多数人(包括绝大多数数据挖掘研究人员)并不这么认为。但是,统计学和数据挖掘的目标非常相似,而且数据挖掘的许多算法确实源于数理统计,统计学对数据挖掘发展的贡献功不可没。

#### 2) 数据挖掘与传统数据分析方法的区别

数据挖掘的本质是一种深层次的数据分析方法。数据分析已有多年的历史,只不过过去数据收集和分析的一般目的是用于科学研究。另外,由于当时计算能力的限制,很难实现对海量数据进行非常复杂的分析。现在,由于各行业业务自动化的实现,商业领域产生了大量的业务数据,这些数据并不是为了分析的目的而收集的,而是在商业活动过程中由于业务需要自然产生的。不再是单纯为了研究,更主要的是为商业决策提供真正有价值的信息和知识,进而使利润最大化。所有企业面临的一个共同问题是企业数据量非常大,而其中真正有价值的信息和知识却很少,因此需要对大量数据进行深入分析,获得有利于提高核心竞争力的信息和知识,如同从矿石中淘金一样,数据挖掘也因此而得名。

数据挖掘与传统数据分析方法的区别主要在于:

(1) 数据挖掘的数据源与以前相比有显著的改变。首先,数据挖掘出现的背景是“数据爆炸而知识贫乏”,它需要处理的数据量达到了“太”(万亿)级以上,比传统数据分析所处理



的数据量超出几个乃至十几个数量级。对于如此大规模的数据,传统的数据分析方法可能根本无法处理,即使能够处理,效率也是一个瓶颈。因此需要对原有的数据分析方法重新检验并加以改进。其次,传统数据分析的数据源一般都是清洁的、结构化的,数据挖掘则是从不完全的、有噪声的、模糊的数据中发现知识。数据的抽取、清洁、转换和集成是数据挖掘的重要组成部分。数据挖掘不仅可以处理结构化的数据,还可以处理半结构化或非结构化的数据。事实上,非结构化的文本挖掘甚至半结构化的 Web 挖掘正是数据挖掘的研究方向之一。

(2) 传统数据分析方法一般都是先给出一个假设然后验证,即在一定意义上是假设驱动的;与之相反,数据挖掘在一定意义上是发现驱动的,模式都是通过大量的探索工作从海量数据中自动提取。这一点是数据挖掘区别于传统数据分析方法以及 OLAP 技术的本质特点。数据挖掘是在事先没有假定想法与问题的情况下,在大量数据中发现隐含的模式。所获得的信息和知识具有预先未知的特征,即数据挖掘要发现那些不能靠直觉发现的甚至是违背直觉的信息或知识,越是出乎意料,可能越有价值。在商业应用中最典型的例子就是一家连锁店通过数据挖掘发现小孩尿布和啤酒之间有着惊人的联系。

### 5.1.2 功能

概括地,数据挖掘的主要功能如下:

#### 1. 概念/类别描述(concept/class description)

概念/类别描述是对数据集做一个简洁的总体性描述并/或描述其与某一对照数据集的差别。

**例 5.1** 收集移动业务每月 ARPU(Average Revenue Per User,每户平均收入)超出 1000 元的客户资料,然后利用数据挖掘可作出总体描述如下:年龄 35~50 岁、工作稳定、月收入 5000 元以上、拥有良好信用度。

**例 5.2** 对比移动业务每月 ARPU 超出 500 元和低于 30 元的两个客户群,然后利用数据挖掘可做出描述如下:每月 ARPU 超出 500 元的客户 80% 以上年龄在 35~50 岁,月收入 5000 元以上;而每月 ARPU 低于 30 元的客户 60% 以上要么年龄过大要么年龄过小,月收入 2000 元以下。

#### 2. 关联分析(association analysis)

从一个数据集中发现关联规则,该规则显示给定数据集中经常一起出现的属性值元组。例如:关联规则  $X \rightarrow Y$  所表达的含义是满足  $X$  的元组很可能满足  $Y$ 。关联分析在交易数据分析、支持定向市场、商品目录设计和其他业务决策等方面有着广泛的应用。

#### 3. 分类和预测(classification and prediction)

分类是指通过分析一个类别已知的数据集的特征建立分类模型,该模型可预测类别未知对象的类别。分类模型可以表现为多种形式,如分类规则(if then)、决策树或数学公式乃至神经网络。预测与分类类似,只不过预测的不是类别,而是连续的数值。

#### 4. 聚类分析(clustering analysis)

聚类分析又称为“同质分组”或“无监督的分类”,即把一组数据划分为不同的“簇”,每一簇中的数据相似而不同簇间的数据则相异,可以通过距离函数等度量相似性。聚类应保证



不同类别间数据的相似性尽可能小,而类别内数据的相似性尽可能大。

### 5. 时间序列分析(time series analysis)

时间序列分析即预测,是指通过对大量时间序列数据的分析找到特定的规则和感兴趣的特性,包括搜索相似序列或者子序列,挖掘序列模式、周期性、趋势和偏差。预测的目的是对未来的情况做出估计。

### 6. 其他功能

除了上述主要功能外,还包括偏差分析(deviation analysis)、孤立点分析(outlier analysis)等。

随着数据挖掘技术的不断发展,将会继续出现新的应用。

## 5.1.3 模型

### 1. 5A 模型

5A 模型是 SPSS 提出的,强调的是数据挖掘工具应具有的功能和能力。5A 模型认为数据挖掘方法学由五个基本元素组成,即 Assess、Access、Analyze、Act 和 Automate。

(1) Assess 正确、彻底地评价任务的需求和数据,正确地理解商业问题和数据,并设计挖掘计划及相关准备任务。

(2) Access 方便、快速地存取任务涉及的数据,要求指定的数据集合符合挖掘的需求和质量。

(3) Analyze 适当、完备的分析技术和工具,要求工具能全面提供适合不同需求的各种挖掘、建模算法。

(4) Act 具有推荐性、说服力的模型演示,提供可视化的模型并能够灵活嵌入到各类展示平台中。

(5) Automate 自动地提供挖掘结果并展现给用户。

### 2. SEMMA 模型

SEMMA 是 SAS 提出的数据挖掘过程模型,由抽样(sample)、探索(explore)、修正(modify)、建模(model)和评估(assess)五个步骤组成,如图 5.1 所示。

#### 1) 数据取样

进行数据挖掘时,首先需要从大量数据中取出一个与所要探索问题相关的数据子集,而不是动用全部数据。犹如对开采出来的矿石首先要进行选矿一样。通过数据筛选,不仅能减少数据处理量,节省系统资源,而且使所反映的规律性更加凸现出来。

#### 2) 数据特征探索、分析和预处理

前面提及的数据取样,多少是带着人们对如何达到数据挖掘目的的先验认识进行操作的。当获得样本数据集后,是否可达到预想的要求;是否存在明显的规律和趋势;因素之间有何相关性;可划分为怎样的类别等都是需要探索的内容。进行数据特征的探索和分析,最好是采用可视化的操作,显示各种统计分析的结果,而且可进行多维、动态甚至旋转的显示。

#### 3) 问题明确化、数据调整和技术选择

通过上述两个步骤,对数据的状态和趋势可能有了进一步的了解,对原先要解决的问题

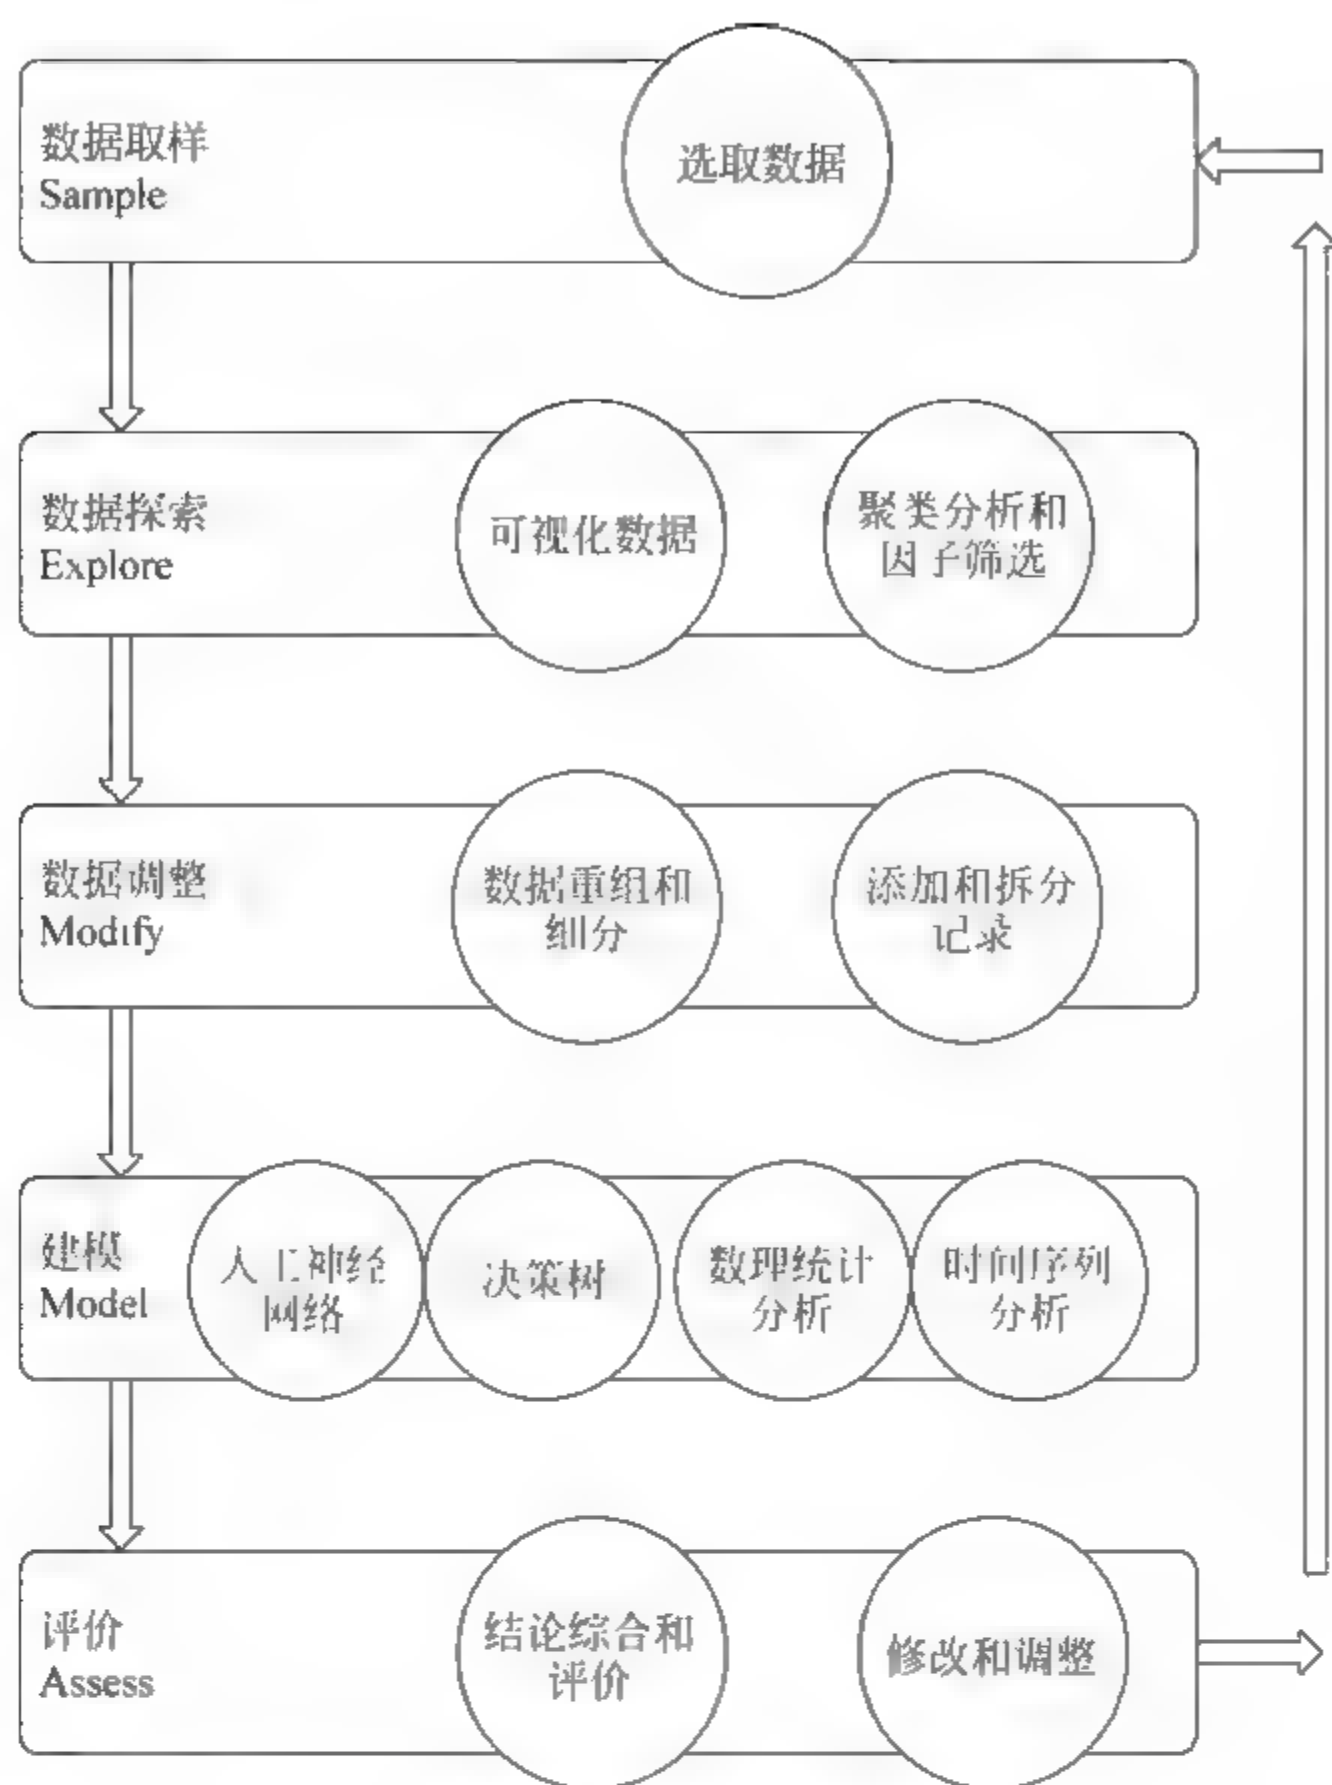


图 5.1 数据挖掘过程模型——SEMMA

可能会进一步明确,这时应尽可能对需求进行量化,这是十分重要的。例如很可能因为诸如质量不好、生产效率低等一些模糊的问题而无法进行有效的数据挖掘。

在问题明确的基础上,可以按照问题的具体要求审视数据集,以确定是否满足需求。Gartner Group 在评论当前一些数据挖掘产品时特别强调指出:在数据挖掘的各个阶段,数据挖掘产品都要让所使用的数据和所建立的模型处于十分易于调整、修改和变动的状态,这样才能保证数据挖掘的有效进行。

针对需要可能要对数据进行增删,也可能按照对整个数据挖掘过程的新认识,组合或生成一些新的变量。

#### 4) 模型的研发、知识的发现

正如 Gartner Group 评论所指出的:数理统计方法还是数据挖掘工作中最常用的主流手段。挖掘过程中可能需要各种不同类型的模型、不同特征数据的回归分析,如正交回归、线性回归、Logistic 回归和非线性回归等,可处理的数据包括实型、有序和属性数据等,并能产生各种有用的统计量和诊断信息。

### 3. CRISP-DM 模型

为了使数据挖掘技术在业界得到更好的应用,欧洲委员会联合一些数据挖掘软件厂商



开发了 CRISP DM(Cross Industry Standard Process for Data Mining)模型,如图 5.2 所示,旨在把数据挖掘过程标准化,使数据挖掘的实施速度更快、成本更低、更可靠并且更易于管理。1996 年 CRISP DM 模型被首次提出,并在各种 KDD 模型中占据领先地位,份额近 60%。

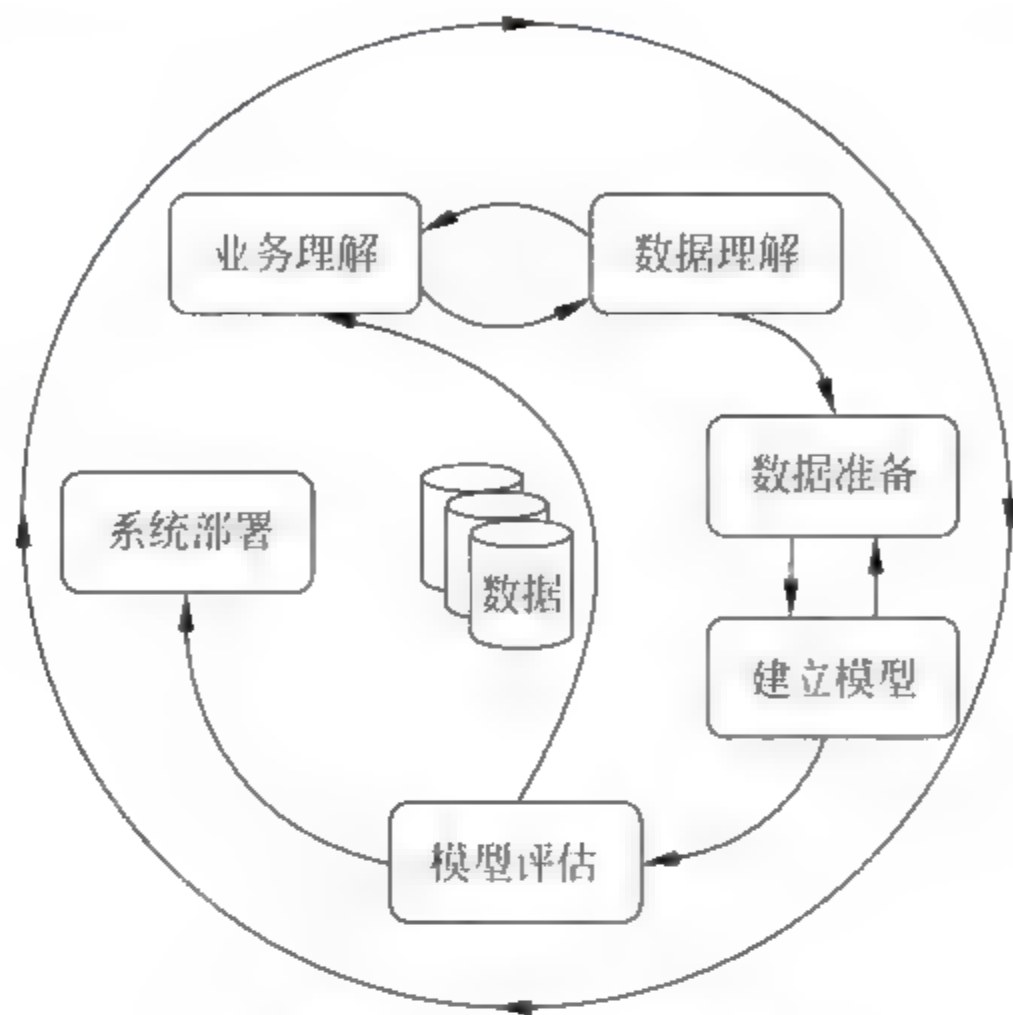


图 5.2 CRISP-DM 模型

CRISP-DM 模型中,数据挖掘过程划分为六个阶段,即:

#### 1) 业务理解(business understanding)阶段

本阶段专注于从商业角度理解项目目标 and 需求,并转化为数据挖掘的问题定义,同时设计一个初始计划。具体包括:

##### (1) 确定业务目标(determine business objectives)

分析员第一步要做的是从商业角度全面理解客户真正希望达到的目的。客户的目标常常具有挑战性但同时又有很多限制,需要很好地权衡。分析员最开始要做的是找到影响整个项目的重要因素。如果缺少这一阶段很可能会导致给出的答案是正确的但是提出的问题却是错的。这一步骤应获得的相关细节包括:

背景(background):了解有关组织或企业商业状况的详细信息。

商业目标(business objectives):从商业角度描述客户的最主要目标,客户通常应该从商业角度提出很多问题,例如一个主要的商业目标是预测客户何时可能流向竞争对手,提出的问题可能就是“一个电信客户所使用的主要业务受理渠道(客户经理、Internet)对他们是否流失是如何起影响作用的?”或是“降低 ATM 交易费能否减少高价值客户的流失?”。

商业成功标准(business success criteria):从商业角度描述一个数据挖掘项目的结果是否成功。可能是以一种明确的方式如减少客户流失率至某个级别或以更一般更主观的方式如“发现有用的联系”,对于后者应该注明是谁作出的这一主观决定。

##### (2) 评估商业环境(assess situation)

这一任务涉及对很多资源、约束、假定等对整个项目计划和目标有影响的因素的仔细考



察。前一个任务只是快速了解大致情况。这一步骤应获得的相关细节包括:

资源列表(inventory of resources):列出与项目相关的全部资源,包括人(领域专家、数据专家、技术支持、挖掘人员)、数据(固定抽取的数据、从数据仓库或业务数据库中获得的数  
据)、计算资源(硬件平台)和软件资源(数据挖掘工具、其他相关资源)。

需求、假定和约束(requirement, assumption and constraint):列出项目的全部需求,包  
括完工日程、对结果的质量要求、安全性以及法律相关问题。列出项目所作的假定以及约  
束,如对资源的约束或对技术的约束,如数据的大小对于建模是可行的。

风险和意外开销(risk and contingency):列出可能导致项目延期或终止的事件,列出  
如果发生风险所带来的意外开销。

术语表(terminology):一个与项目有关的术语表应该有两个,一个是商业术语表,另一个  
是数据挖掘的技术术语表。

成本和收益(cost and benefit):项目的成本收益分析,比较项目的潜在收益和耗费成  
本。这项工作应该非常具体,如采用商业上的货币度量方式。

### (3) 确定数据挖掘目标

商业目标用商业术语说明,数据挖掘目标则用技术术语说明。如商业目标是“提高已有  
客户的销售量”,而数据挖掘目标可能是“在给定其过去三年的购买情况数据、人口信息(年  
龄、收入和所在城市等)和商品价格条件下,预测某个客户可能会购买多少”。这一步骤的相  
关细节包括:

数据挖掘目标(data mining goal):描述项目预期的哪些输出会使商业目标获得成功。

数据挖掘成功标准(data mining success criteria):用技术术语定义项目成功时的结果。  
如果商业目标是以主观方式描述的,则此处的描述可能也将以主观术语描述,但做出描述  
的人应该被注明。

### (4) 提出项目计划(produce project plan)

描述一个可行的计划以达到数据挖掘目标和商业目标。计划应该预先明确项目的余下  
步骤包括工具和技术初步选取。这一步骤的相关细节包括:

项目计划(project plan):列出项目的执行阶段,包括时间、所需资源、输入、输出和依赖  
关系,可能会在某些环节循环或重复,项目的计划根据实际需要动态更新。

初步估计工具和技术(initial assessment of tool and technique):对使用的工具和技术  
做出初步估计和计划。

## 2) 数据理解(data understanding)阶段

本阶段,先收集初步的数据,然后了解并熟悉数据,以识别数据质量、找到对数据的基本  
观察或假设隐含的信息以检测出感兴趣的数据子集。具体包括:

### (1) 收集原始数据(collect initial data)

获取在项目资源中所需的原始数据,这个过程可能包括数据理解,这相当于初步的数据  
准备过程。如果数据源分散则需要对数据进行集成,生成原始数据收集报告(initial data  
collection report),其中列出获得的数据集,列出其在项目中的位置、获取数据的方法和遇到  
的任何问题及其解决方法。

### (2) 描述数据(describe data)

查看数据的表面特性,生成数据描述报告(data description report),描述数据的格式、



数据质量、字段数、记录数以及其他各种表面特性。

### (3) 探索数据(explore data)

该任务为进行数据挖掘进行一定查询、可视化以及报告工作。包括分析关键属性、预测任务的目标属性、属性间的关系、简单聚集的结果、重要子集的特征和简单的统计分析。这些分析可能直接对数据挖掘目标产生影响也可能对数据描述、数据质量报告或数据准备有用。生成数据探索报告(data exploration report)描述此项工作的结果,包括最初的发现、原始假设及其对项目的影响。该报告可能有一些图等表示数据的特性或有意义的子集。

### (4) 检查数据质量(verify data quality)

检查数据质量,可以提出类似于数据是否完整(是否覆盖全部情况)、是否正确,如果有错误,错误率是多少,数据中是否有缺失值,如果存在缺失值则它们是如何表示的,在何处发生及发生率是多少等问题。生成数据质量报告(data quality report),列出数据质量验证结果,如果存在质量问题列出可能的解决方案,解决方案同时依赖于数据以及商业知识。

## 3) 数据准备(data preparation)阶段

本阶段包括从数据构造到最终数据集(将要输入建模工具的数据)的所有活动。数据准备任务可能需要执行很多次,并没有任何规定的顺序。任务包括表、记录属性的选择以及为适应建模工具的要求对数据的转换和清洗。具体包括:

### (1) 数据选择(select data)

选择分析用的数据。数据选择的标准是与挖掘目标、质量和技术约束相关。数据的选择包括行和列的选择。生成所包含/不包含的数据清单(rationale for inclusion/exclusion),列出所包含/不包含的数据清单及其原因。

### (2) 数据清洁(clean data)

提高数据质量以达到数据挖掘分析的要求。可能包括选择已经清洁的数据子集,对于错误数据的修正等。生成数据清洁报告(data cleaning report)描述应该采取哪些方法和措施解决数据质量问题,这些问题在验证数据质量报告中曾经提出。

### (3) 数据创建(construct data)

该任务根据需要产生新的派生属性、新的记录或变换已有属性值。这一步骤的相关细节包括:

衍生属性(derived attribute):将已有属性组合或变换成更有利于知识挖掘的衍生属性,如面积=长×宽。

生成记录(generate record):说明新生成的数据,例如客户去年没有购买记录,其有关购买数量的记录不存在,创建一条记录将其购买数量设置为0以利于分析。

### (1) 数据合并(integrate data)

使用一些方法将多个表或记录合并为新的记录或值。包括合并数据(merged data),合并表(将两个或多个对同一对象有不同信息的表中的记录合成在一张表)。合成数据也包括聚集,即将若干记录的信息累计生成新的信息。

### (2) 数据格式化(format data)

格式化数据是指可能因为建模工具的要求改变数据的形式。这一步骤的相关细节包括:

重新格式化数据(reformatted data):有些工具对属性的顺序有要求,例如第一个域是记录标识符,最后一个域用于预测模型的输出。记录的顺序同样很重要,可能某些工具需要



记录根据输出值排序,通常情况下表中记录是有顺序的,但算法要求使用乱序的数据,例如神经网络在记录是随机排列时效果最好,通常无需人的干预而由工具本身完成。除此之外,还有一些数据有词法格式化的需求,如对于逗号分割的文本字段可能需要删去逗号,字符串最长不超过 32 个字符等。

#### 4) 建立模型(modeling)阶段

本阶段可以选择各种建模技术,各类模型参数也可以调整优化。对同一个数据挖掘问题有多种可用技术,某些技术对数据的形式有一定要求,因此常常要退回到数据准备阶段。具体包括:

##### (1) 选择建模技术(select modeling technique)

确定数据挖掘算法和参数,可能会利用多种算法。作为建模任务的第一步,应该选择实际使用的建模技术。与在商业理解阶段选择建模技术相比本阶段更加明确指定具体的建模技术,如明确决策树是使用 C4.5 算法构造还是 BP(back propagation)神经网络算法。如果使用多种技术,需要对每种技术分别进行此项工作。选择什么样的模型决定了需要对数据做哪些预处理,如神经网络模型需要转换数据,有些数据挖掘工具可能对输入数据的格式有特定限制。一旦所有的数据准备好之后,可以开始训练模型。这一步骤除建模技术还包括建模假设(modeling assumption),即很多建模技术对数据都做一定的假设,例如所有属性具有同样的权重,没有缺失值,分类属性必须是符号化的等。

##### (2) 测试方案设计(generate test design)

设计某种测试模型的质量和有效性的机制。在真正生成模型之前,需要建立一个测试过程或机制以保证模型的质量和正确性,例如对于分类很自然地使用错误比率作为分类模型的质量评价度量。因此可以将数据分为训练集和测试集,在训练集上建立模型,在测试集上测试模型的质量。这一步骤的相关细节包括:

测试方案(test design):该方案说明如何训练、测试和评估模型,其中一个主要部分是数据如何划分为训练集、测试集和评估集。

- 模型训练(build model):在准备好的数据集上运行数据挖掘算法,得出一个或者多个模型。
- 模型测试评估(assess model):根据测试方案进行测试,从数据挖掘角度确定数据挖掘目标是否成功。

#### 5) 模型评估(evaluation)阶段

在最终扩展模型前需要彻底地评价模型,对所建模型再次考察其执行步骤并确信其正确地达到了商业目标。这里,一个关键的目的是确定是否有某些重要的商业问题还没有充分地考虑到。具体包括:

(1) 结果评估(evaluate result):从商业角度评估获得的模型,甚至实际试用该模型测试其效果。

(2) 过程回顾(review process):回顾项目的所有流程,确定每一阶段都没有失误。

(3) 确定下一步工作(determine next step):根据结果评估和过程回顾得出的结论,确定是部署该挖掘模型还是从某个阶段重新开始。

#### 6) 系统部署(deployment)阶段

所获得的挖掘结果和知识应该采用用户可以使用的方式组织和表示。可以简单到只有



一份报告也可以实现一个可以重复的挖掘过程或系统。很多情况下,这将由用户而非分析员实施。具体包括:

- 部署计划(plan deployment):对在业务运作中部署模型做出计划;
- 监控和维护计划(plan monitoring and maintenance):如何监控模型在实际业务中的使用情况,如何维护该模型;
- 做出最终报告(produce final report):总结项目经验和项目结果;
- 项目回顾(review project):回顾项目的实施过程,总结经验教训,预测数据挖掘的运行效果。

为了保证数据挖掘项目的可靠性和可管理性,CRISP-DM模型规定应该产生11个报告,即业务理解报告、原始数据收集报告、数据描述报告、数据探索报告、数据质量报告、数据集描述报告、模型训练报告、模型评估报告、部署计划、监控和维护计划及总结报告。通过这些报告,可以有效地控制数据挖掘的项目进程,减少风险。

表5.2所示为各个阶段的通用任务,其中黑体表示任务的名称,斜体表示任务的输出。

表 5.2 CRISP-DM 各阶段通用任务

Business Understanding	Data Understanding	Data Preparation	Modeling	Evaluation	Deployment
<b>Determine Business Objectives</b> <i>Background Business Objectives Business Success Criteria</i>	<b>Collect Initial Data</b> <i>Initial Data Collection Report</i>	<b>Data Set</b> <i>Data Set Description</i>	<b>Select Modeling Technique</b> <i>Modeling Technique Modeling Assumptions</i>	<b>Evaluate Results</b> <i>Assessment of Data Mining Results w.r.t. Business Success Criteria</i>	<b>Plan Deployment</b> <i>Deployment Plan</i>
<b>Assess Situation</b> <i>Inventory of Resources Requirements, Assumptions, and Constraints Risks and Contingencies Terminology Costs and Benefits</i>	<b>Describe Data</b> <i>Data Description Report</i>	<b>Select Data</b> <i>Rationale for Inclusion / Exclusion</i>	<b>Generate Test Design</b> <i>Test Design</i>	<b>Approved Models</b>	<b>Plan Monitoring and Maintenance</b> <i>Monitoring and Maintenance Plan</i>
<b>Determine Data Mining Goals</b> <i>Data Mining Goals Data Mining Success Criteria</i>	<b>Explore Data</b> <i>Data Exploration Report</i>	<b>Clean Data</b> <i>Data Cleaning Report</i>	<b>Build Model</b> <i>Parameter Settings Models Model Description</i>	<b>Review Process</b> <i>Review of Process</i>	<b>Produce Final Report</b> <i>Final Report Final Presentation</i>
<b>Produce Project Plan</b> <i>Project Plan Initial Assessment of Tools and Techniques</i>	<b>Verify Data Quality</b> <i>Data Quality Report</i>	<b>Construct Data</b> <i>Derived Attributes Generated Records</i>	<b>Assess Model</b> <i>Model Assessment Revised Parameter Settings</i>	<b>Determine Next Steps</b> <i>List of Possible Actions Decision</i>	<b>Review Project Experience</b> <i>Documentation</i>
		<b>Integrate Data</b> <i>Merged Data</i>			
		<b>Format Data</b> <i>Reformatted Data</i>			

CRISP DM模型给出了整个数据挖掘项目的流程。对于一个数据挖掘系统,实际上只涉及其中的数据准备、模型训练、模型评估三个阶段,而业务理解和数据理解则是为数据挖掘系统准备输入,模型部署是数据挖掘系统的实施。

#### 5.1.4 展望

近年来,数据挖掘的研究重点逐步从算法研究转向系统应用,注重多种策略和技术的集成,以及多学科之间的渗透和交叉,如1998年在美国纽约举行的第四届知识发现与数据挖掘国际学术会议上不仅进行了学术讨论,并且有三十多家软件公司展示了数据挖掘软件产



品,不少软件已在北美、欧洲得到应用。

目前,数据挖掘在银行、电信、保险、交通和零售(如超市)等领域都有不少成功的应用案例,随着商业竞争日趋加剧,对数据挖掘的需求将愈加紧迫。

就应用领域而言,当前数据挖掘的热点包括网站的数据挖掘、生物信息或基因(bioinformatics/genomics)挖掘、文本挖掘(text mining)和多媒体挖掘(multimedia mining)等。下面分别进行简要介绍。

### 1. 网站的数据挖掘

当前 Internet 上各类电子商务网站风起云涌,电子商务的业务竞争比传统的业务竞争更加激烈。客户从一个电子商务网站转换到竞争对手那边,只需点击几下鼠标即可,电子商务环境下客户保有比传统商业更加困难,若想在激烈的竞争中生存,则必须比竞争对手更了解客户。电子商务网站每天都可能有上百万次的在线交易,生成大量的日志文件(log file)和登记表,如何对这些数据进行分析 and 挖掘,充分了解客户的喜好、购买习惯甚至是客户一时的冲动,设计出满足不同客户群需求的个性化网站,进而增强竞争力,几乎是势在必行。

就分析和建模而言,网站的数据挖掘和现有的数据挖掘差别并不是特别大,很多方法和分析思路都可以借鉴,所不同的是网站的数据格式有很大一部分来自于点击流,与传统的数据格式有所区别。因而对电子商务网站进行数据挖掘所做的主要工作是数据准备。目前,有很多厂商正致力于开发专门的软件。

### 2. 生物信息或基因挖掘

生物信息或基因数据挖掘则完全属于另一个领域,其商业价值很难估计,但对于人类却受益匪浅。例如,基因组合千变万化,患有某种疾病的人的基因和正常人的基因差别到底多大?能否找出差异,进而加以改变使之成为正常基因?这都需要数据挖掘技术的支持。

对于生物信息或基因的挖掘和通常意义的数据挖掘相比,无论在数据复杂度、数据量以及分析和建模上都复杂得多。就算法而言,需要一些新的和好的算法,目前很多厂商致力于这方面的研究;就技术和软件而言,还远未成熟。

### 3. 文本挖掘

文本挖掘是另外一个人们颇感兴趣的领域,例如客户服务中心把同客户的谈话内容转换为文本,再进行挖掘,进而了解客户对服务的满意度和客户的需求以及客户之间的相互关系等。

无论是在数据结构还是在分析方法方面,文本挖掘和前面提及的数据挖掘相差很大。文本挖掘并不是一件容易的事情,尤其是在分析方法方面,还有很多需要研究的专题。目前市场上有一些类似的软件,但大部分只是把文本移来移去,或简单地计算某些词汇出现的频率,并不具有真正的分析功能。

### 4. 多媒体挖掘

多媒体挖掘主要包括两个方面,基于描述的检索是指基于图像描述创建索引并实现对象检索,如关键字、标题、尺寸和创建时间等。若通过人工实现极为费力,若自动实现往往结果不甚理想;基于内容的检索是指支持基于图像内容的检索,如颜色、质地、形状和对象等。

当前,数据挖掘研究的焦点集中在以下几个方面:

#### 1) 发现语言的形式化描述

即研究专门用于知识发现的数据挖掘语言,寻求类似于数据库 SQL 语言的数据挖掘语



言,使挖掘过程走向形式化和标准化。

#### 2) 寻求数据挖掘过程的可视化方法

使知识发现的过程能够被用户理解,便于在知识发现过程中实现人机交互。

#### 3) 研究在网络环境下的数据挖掘技术

特别是在 Internet 上建立 Web 服务器,并且与数据库服务器配合,实现 Web 挖掘(Web mining)。

#### 4) 加强对各种非结构化数据的挖掘

如对文本、图形、视频、音频乃至综合多媒体数据的挖掘。

#### 5) 知识的维护更新

数据挖掘的结果——知识是具有时效性的,需要研究知识的维护更新技术,如知识的增量更新和模型进化等。

## 5.2 实现

数据挖掘的实现过程如图 5.3 所示。




图 5.3 数据挖掘的实现过程

### 1. 数据准备

数据挖掘的处理对象是海量数据,它们一般存储在数据库系统,是长期积累的结果。但往往不适合直接进行数据挖掘,需要进行预处理。数据预处理包括数据的选择、清洁(消除噪声、冗余数据)、推测(推算缺失数据)、转换(离散型数据与连续型数据之间的转换)、数据缩减(减少数据量)等。

数据准备是数据挖掘的第一个步骤,其成功与否将影响到数据挖掘的效率、准确性以及最终模型的有效性。

### 2. 数据挖掘

数据挖掘是最为关键的一个步骤,它根据挖掘的目标,选取相应算法的参数,分析数据,得到可能形成知识的模型,目前常用的算法包括决策树、分类、聚类、粗糙集、关联规则、人工神经网络和遗传算法等。

### 3. 模式的评估、解释

通过上述步骤得到的模式,有可能是没有意义或没有实用价值的,因此需要评估,确定哪些是有效的、有用的模式。此外,大部分模式是数学的表达式,很难被人理解,还需要将其解释成可理解的方式呈现给用户。

#### 4. 知识运用

发现知识是为了运用,如何运用知识也是一个关键。运用知识主要有两种途径:其一是只需看知识本身描述的关系或结果,就可以对决策提供支持;其二是要求对新的数据运用知识,由此可能产生新的问题,并需要对知识做进一步优化。

数据挖掘过程可能需要多次的循环反复,一旦某个步骤与预期目标不符,则需要回溯到前面的步骤,重新调整和执行。

在数据挖掘的实现过程中,不同步骤需要具有不同专长的人员参与完成,大致可以分为三类:

- (1) 业务分析人员:要求精通业务,能够确定用于数据定义和挖掘算法的业务需求。
- (2) 数据分析人员:精通数据分析技术,熟练掌握统计学方法,有能力把业务需求转化为数据挖掘的各步操作,并为每步操作选择合适的技术。
- (3) 数据管理人员:精通数据管理技术,负责从数据库或数据仓库中收集数据。

由此可知,数据挖掘是一个多领域专家合作的过程,同时也是一个在资金和技术上高投入的过程,这一过程需要反复进行,以不断地趋近事物的本质,不断地优化问题的解决方案。

一般地,企业实施数据挖掘的方式主要有三种,即:

- 购买成熟的模型
- 购买通用的数据挖掘软件
- 构建数据挖掘系统

第一种方式实现简单,可以直接应用,但是要求模型所模拟的环境必须和企业的产品、客户以及市场条件相类似。当模型涉及的环境条件改变时,不能根据环境的变化做出修改和调整;第二种方式可以利用数据挖掘系统根据企业自身的数据生成模型。但是,一个通用的数据挖掘系统在对特定的商业问题的理解上可能需要做很多工作。同时,如何与企业现有系统自动化集成也是一个需要着重考虑的问题;第三种方式可以较好地解决与现有系统集成的问题,并可以直接面向特定的商业问题的解决。但是这种方式实现较复杂,项目实施周期长,成本较高。

当然,企业也可以把上述三种方式结合起来,例如购买包含模型的数据挖掘软件、购买通用数据挖掘软件进行针对本企业的二次开发等。

以电信行业为例,建议构建一个适合企业自身特点的数据挖掘系统是较好的选择(包括购买针对本行业特点开发的数据挖掘系统)。

### 5.3 工具

#### 5.3.1 概述

数据挖掘的应用前景非常广阔,相关产品的研发方兴未艾。目前,已经出现了几十种商用数据挖掘产品和工具。

数据挖掘工具的发展大致经历了四个阶段。

第一代数据挖掘工具支持一种或少数几种数据挖掘算法,可以挖掘向量数据,挖掘时一般一次性调入内存进行处理。典型产品包括 CBA 和 Salford Systems 公司早期的 CART



系统。

第二代数据挖掘工具支持数据库和数据仓库,和它们之间有高性能接口,具有较好的可扩展性,能够挖掘更大、更复杂以及高维的数据集。通过支持数据挖掘模式和数据挖掘查询语言(DMQL)增加了系统的灵活性。典型产品是 DBMiner。

第三代数据挖掘工具的特点是能够挖掘 Internet/Extranet 的分布式和高度异构的数据,并且能够有效地与操作型系统集成。其关键技术之一是对建立在异构系统上的多个预测模型以及管理这些预测模型的元数据提供第一级的支持,但不支持移动环境。典型产品是 SPSS Clementine。

第四代数据挖掘工具能够挖掘嵌入式系统、移动系统和普遍存在的计算设备产生的各种类型的数据。

数据挖掘工具的应用主要分为三类,即:

(1) 通用的数据挖掘工具,不区分具体数据的含义,采用通用的挖掘算法,处理常见的数据类型。通用的数据挖掘工具可以实现多种模式的挖掘,挖掘什么、用什么挖掘都由用户根据实际需求选择,如 SAS Enterprise Miner、IBM Intelligent Miner、UnicaPRW、SPSS Clementine、SGI MineSet、Oracle Darwin 和 Angoss KnowledgeSeeker 等。

(2) 综合的数据挖掘工具,能提供管理报告、在线分析处理和普通的数据挖掘能力,如 Cognos Scenario 和 Business Object 等。

(3) 专用的数据挖掘工具,面向特定应用的数据挖掘工具,针对某一特定领域的问题提供解决方案。在设计算法时充分考虑了数据、需求的特殊性,并进行优化。其针对性比较强,只能用于一种应用,因此往往采用特殊的算法,可以处理特殊的数据,实现特殊的目的,发现的知识可靠度较高,如 KDI(零售)、Options & Choices(保险)和 HNC(欺诈行为探查)等。

各种数据挖掘工具各有千秋,适用不同的环境,了解这些工具的特性,并根据企业特点选择合适的数据挖掘工具是一个非常具有挑战性的问题。由于各公司的背景、财务、挖掘水平各不相同,对数据挖掘工具的需求也不尽相同。目前,国际上在数据库、数据仓库的性能评测方面最权威的机构是交易处理性能委员会(Transaction Processing Performance Council,TPC)。但是,到目前为止数据挖掘方面可供参考的权威评估报告非常少。最近的一份完整而权威的数据挖掘工具评估报告是由 JohnF. ElderIV 和 DeanW. Abbott 在 1998 年完成的,可以说它已经过时了。

一般而言,对数据挖掘工具的选择可考虑以下方面:

(1) 公司的数据挖掘需求期限。如果是短期行为,可购买那些能解决特定问题的软件包或外包给咨询公司;如果是长期使用,需要购买功能较丰富,使用较方便,维护升级较好的企业型数据挖掘工具。

(2) 公司的数据挖掘经验和水平。公司应该根据内部数据挖掘团队的经验和水平,选取一些经过基本培训后就能掌握的工具,而不是盲目求好,最终导致因不会使用工具而将其束之高阁,从而造成不必要的浪费。在选择数据挖掘工具前,必须对公司现有的数据进行评估。如果不具备针对业务主题进行挖掘(例如风险预测)的数据或者现有格式不能满足数据挖掘工具的需求,则需要数据具备后,再考虑购买。

(3) 公司的预算。当然,在选择数据挖掘工具时,公司也需要结合自身的财务预算做出



决定。

(4) 工具的性能。好的工具可以更有效地挖掘出准确、高价值的信息和知识,所以工具性能的评估也是相当重要。

### 5.3.2 比较

下面将从运行平台、易用性、算法、灵活性(算法参数、选项等)和挖掘过程自动化等方面,对表 5.3 中常见的几种数据挖掘工具进行比较。

表 5.3 常见的数据挖掘工具

产 品	公 司	主 页	版本
SPSS Clementine	Integral Solutions	<a href="http://www.isl.co.uk/clem.html">http://www.isl.co.uk/clem.html</a>	4.0
Darwin	Thinking Machines	<a href="http://www.think.com/html/products/products.htm">http://www.think.com/html/products/products.htm</a>	3.0.1
Enterprise Miner	SAS Institute	<a href="http://www.sas.com/software/components/miner.html">http://www.sas.com/software/components/miner.html</a>	Beta
Intelligent Miner	IBM	<a href="http://www.software.ibm.com/data/iminer/">http://www.software.ibm.com/data/iminer/</a>	2
PRW	Unica Technologies	<a href="http://www.unica-usa.com/prodinfo.htm">http://www.unica-usa.com/prodinfo.htm</a>	2.1
Scenario	Cognos	<a href="http://www.cognos.com/busintell/products/index.html">http://www.cognos.com/busintell/products/index.html</a>	2

#### 1. 支持的平台及数据库连接

数据挖掘工具所支持的平台和数据库连接是影响其性能的重要因素。一个只有 PC 单机版的工具在处理大量数据时会存在严重的效率问题,而一个具有跨平台的 C/S 架构的工具可能会具有更好的扩展性(scalability)。而从数据库中存取数据的效率更是每个数据挖掘工具必须考虑的重要问题。常见的数据挖掘工具在平台和数据库连接方式上的比较如表 5.4 所示。

表 5.4 常见的数据挖掘工具在平台和数据库连接方式上的比较

产 品	单 机 版	C/S 版	数 据 源
SPSS Clementine	PC 和 UNIX	无	ODBC
Darwin	无	UNIX Server/PC Client	ODBC
Enterprise Miner	PC	UNIX Server/PC Client 和 NTServer/PC Client	ODBC 和 Native Database Drivers
Intelligent Miner	PC	UNIX Server/PC Client	Native Database Drivers
PRW	PC	无	ODBC
Scenario	PC	无	仅支持数据库文件(如 DBase 等)

可以看到这些数据挖掘工具一般都有 PC 的单机版,但并不是每一个都有 UNIX 平台的 Server 端。而且虽然它们都可以与数据库相连接,但连接方式各不相同,可能会存在很大的效率差别(更具体的连接方式可查看相关产品手册)。

#### 2. 算法

算法是数据挖掘工具的核心,是区别于其他数据分析工具的主要因素。一个数据挖掘工具支持的算法在很大程度上体现了其性能。各种数据挖掘工具支持的主要算法如表 5.5



所示。

表 5.5 各种数据挖掘工具支持的主要算法

算 法	SPSS Clementine	Darwin	Enterprise Miner	Intelligent Miner	PRW	Scenario
决策树	有	有	有	有	无	有
神经网络	有	有	有	有	有	无
回归分析	有	无	有	有	有	无
径向基函数 (Radial Basis Function, RBF)	无	有	无	有	有	无
最近邻	无	无	有	无	有	无
最近均值	无	无	无	无	有	无
Kohonen 自组织映射	有	无	有	无	无	无
聚类	有	无	无	有	有	无
关联规则	有	无	无	有	无	无

表 5.5 中列出的只是所支持算法的大致类别,事实上还有其他算法类(如时间序列等)。而且,对于同一类算法各个工具采用的具体算法也不尽相同。由于采用的算法不同,它们表现出大不相同的效率和结果。

在算法参数控制和扩展功能方面,对比上述数据挖掘工具可以发现 Enterprise Miner 和 PRW 对参数控制实现的较好,而这方面 Intelligent Miner 较弱。几乎所有的工具都提供对决策树实数值的处理和图形展示等功能,但只有 SPSS Clementine 和 Scenario 较好地实现了决策树的修剪功能。此外,神经网络的功能扩展方面也差别较大。

### 3. 易用性

作为商用产品,易用性是提高用户满意度和市场占有率的重要因素。表 5.6 从数据装载和操作、模型建立、模型理解和技术支持四个方面对上述常见数据挖掘工具进行了比较。

表 5.6 常用数据挖掘工具在易用性方面的比较

产 品	数据装载和操作	模型建立	模型理解	技术支持	总体感觉
SPSS Clementine	+++	+++	+++	+++	+++
Darwin	++	++	+++	++	++
Enterprise Miner	++	++	++	++	++
Intelligent Miner	++	++	++	++	++
PRW	+++	+++	+++	+++	+++
Scenario	++	+++	+++	++	+++

注: + 表示较好, ++ 表示好, +++ 表示非常好。

显然它们都具有较好的易用性,当然还是有些差别的。

SPSS Clementine、Enterprise Miner、PRW、Scenario 可以自动读入数据的第一行以决定域名和数据类型,Darwin 必须在一个说明文件中注明,而 Intelligent Miner 则提供对话

框输入。各种工具都提供对列的操作(如创建新列、合并列等)和对行的操作(如取样、测试集和训练集的划分等)。

与研究性的平台相比,可视化是商用数据挖掘工具着重考虑的方面。Intelligent Miner、Enterprise Miner 和 Scenario 都具有图形化的展示,而 SPSS Clementine 和 Darwin 则提供基于文本的规则说明。对于柱状图、饼图和曲线等其支持程度也各有不同。

4. 挖掘自动化

这里的挖掘自动化是指产品以何种手段使用户完成数据源选择、数据转换、算法选择和结果保存等一系列步骤之间的衔接。各种常见数据挖掘工具支持的手段如表 5.7 所示。

表 5.7 常见数据挖掘工具挖掘自动化的比较

产 品	对挖掘自动化的支持
SPSS Clementine	支持可视化编程和编程语言
Darwin	支持编程语言
Enterprise Miner	支持可视化编程和编程语言
Intelligent Miner	仅提供向导界面,不支持编程
PRW	具有一个实验管理组件,支持宏
Scenario	自动化支持较弱,很多过程需手工完成

SPSS Clementine 和 Enterprise Miner 支持的可视化编程是指利用拖拉小图标建立连接的手段描述整个过程,而 IBM 的 Intelligent Miner 则提供一个向导使用户在每个步骤上做出选择。

表 5.7 给出的并不是所有可能的挖掘自动化支持手段,事实上有许多其他工具包含强大的脚本支持(CART、S-Plus 等),S-Plus 甚至支持 C/C++ 编程。

上述常用的数据挖掘工具各自适用不同的环境。IBM 的 Intelligent Miner 在市场上比较领先并提供良好的技术支持; SAS 的 Enterprise Miner 明显地偏向统计(因此更适用于统计环境)。在不清楚哪种工具更好的情况下 Unica PRW 是较好的选择,Cognos Scenario 则是其数据仓库系列产品的重要组件。



## 第6章 聚类分析

聚类分析(clustering analysis)是依据事物的某些属性将其聚集成类。使类间相似性尽量小,类内相似性尽量大,即“物以类聚,人以群分”。

聚类不同于分类(classification),聚类是一种无监督的学习,无需任何先验知识,直接从数据对象中发现有意义的结构,输入对象被划分到一个未知的类;分类则是一种有监督的学习,依据已知的属性值对对象进行分类,输入对象被划分到一个已预先定义的类。

聚类一直是生物学、心理学、医学、考古学、图像处理、市场营销、机器学习、模式识别、数据挖掘及遥感等众多工程和技术领域的研究热点。此外,聚类还可以用作独立的数据挖掘工具,以了解数据的分布情况,或作为其他数据挖掘算法的预处理步骤等。

聚类分析是一个古老的问题,它伴随着人类社会的发展而不断深入。最初,聚类是统计学的一个分支,如经典的多元统计法等。随后,提出了依据对象属性值的相似度实现聚类的相似聚类法。相似聚类法又分为系统聚类(预先不确定分类数目)和动态聚类(预先已确定分类数目)。相似聚类法有着广泛的应用,但同时也存在一些不足之处。本质上,相似聚类法属于上下文无关的聚类,即对象间的相似性度量完全依赖于对象本身的属性,并不受其上下文的影响,这对于“静态”数据的聚类是可行的,但对于“动态”数据,则聚类结果无法令人满意。继而,人们提出了环境聚类法,旨在将人们的注意力从客体的相似性推广到相似性以外,尽管所得到的类提供了更多的信息,但环境聚类法与相似聚类法一样,都是概念无关的,即聚类结果不易理解。为了克服上述局限性,提出了概念聚类,使聚类的演化过程发生了质的变化。从概念聚类的角度看,一些对象之所以聚成一类,一方面是因为它们在某些属性上彼此相似或是与其上下文存在某种内在的联系;另一方面是因为这些对象聚集在一起可以表达某一概念,而这一概念所表征的是这些对象作为一个整体所具有的共同性质。概念聚类由两个搜索过程组成,即在概念层次空间的搜索,以确定较理想的概念层次结构;在可能的聚类空间的搜索,以确定较合适的划分以及在概念描述空间的搜索,为所产生的聚类赋予较合适的概念描述。但是由于搜索往往采用穷尽法或爬山法,因此存在着提高搜索效率或避免局部极小值等问题。

上述的聚类方法均没有考虑到聚类的目标,在一定程度上存在“答非所问”的现象。实际中普遍使用的是目标聚类法,其设计简单,应用范围广,并且可以转化为优化问题,借助于经典的非线性规划方法求解,便于计算机实现,因此目标聚类法是聚类研究的热点。

同时,聚类也是一个困难的问题。它运用数学方法研究和处理所给对象的分类以及各类别之间的亲疏程度,是在对数据不做任何假设的前提下进行分析。在人工智能和模式识别领域,聚类亦称为无先验学习或无监督学习。此外,现实世界中许多事物之间并无明显的划分,彼此之间的关系具有一定的模糊性和不确定性,需要将模糊集合理论引入聚类,即所谓的模糊聚类。

按照划分的结果,聚类可分为硬聚类和模糊聚类两种。硬聚类是指每个对象仅属于距离最近的聚类中心所属的类,非此即彼。例如硬c均值(Hard c means, HCM)和 Kohonen



学习矢量量化(Learning Vector Quantization, LVQ)等;模糊聚类是指每个对象以不同的隶属度或概率属于一个或多个类,如模糊c均值(Fuzzy c-means, FCM)。显然,硬聚类是模糊聚类的一个特例。

下面将分别介绍硬聚类和模糊聚类。

## 6.1 硬聚类

### 6.1.1 算法种类

目前聚类算法已有上百种之多,而且还有许多新方法不断涌现。概括而言,聚类算法主要分为以下几类:

#### 1. 基于划分的聚类算法

给定一个 $n$ 个对象或元组的数据集合,划分法构造数据的 $k$ 个划分,每个划分代表一个聚簇,并且 $k \leq n$ 。首先给定一个划分数目 $k$ ,创建一个初始划分,然后利用迭代,通过对象在划分间移动以改进划分。为了达到全局最优,划分法可能穷举所有可能的划分。实际上,往往采用如下的启发式搜索方法,即:

(1)  $k$ 均值法 该算法中每一簇用该簇对象的平均值表示,使所有对象到聚类中心的距离平方和最小。

(2)  $k$ 中心点算法 该算法中每一簇用接近聚类中心的一个对象表示。

上述两种方法对于小的数据集合非常有效。为了处理大规模数据集,出现了CLARA、CLARANS等改进算法。此外,ISODATA也是一种自动进行类的合并和分裂的基于划分的聚类方法。

基于划分的聚类算法适用于凸集(如图6.1所示)、类间距较远且类直径相差不悬殊的情况,否则会出现错误。



图 6.1 凸集和非凸集

本质上,概念聚类是基于划分的聚类的一种延伸,它用描述对象的一组概念取值将数据划分为不同的类,而不是基于几何距离实现对象之间的相似性度量。概念聚类能够输出不同类以确定其属性特征的覆盖,并对聚类结果进行解释。

#### 2. 基于层次的聚类算法

基于层次的聚类算法是指对给定数据集进行层次分解。根据层次形成的方式不同,分为凝聚(agglomerative or merging)和分裂(divisive or splitting)两种方式,如图6.2所示。

其中,凝聚是指首先将每个对象作为单独的一簇,然后相继合并相近的对象或簇,直到所有的簇合并为一个,或者满足终止条件;分裂是指首先将所有对象置于一个簇中,通过迭



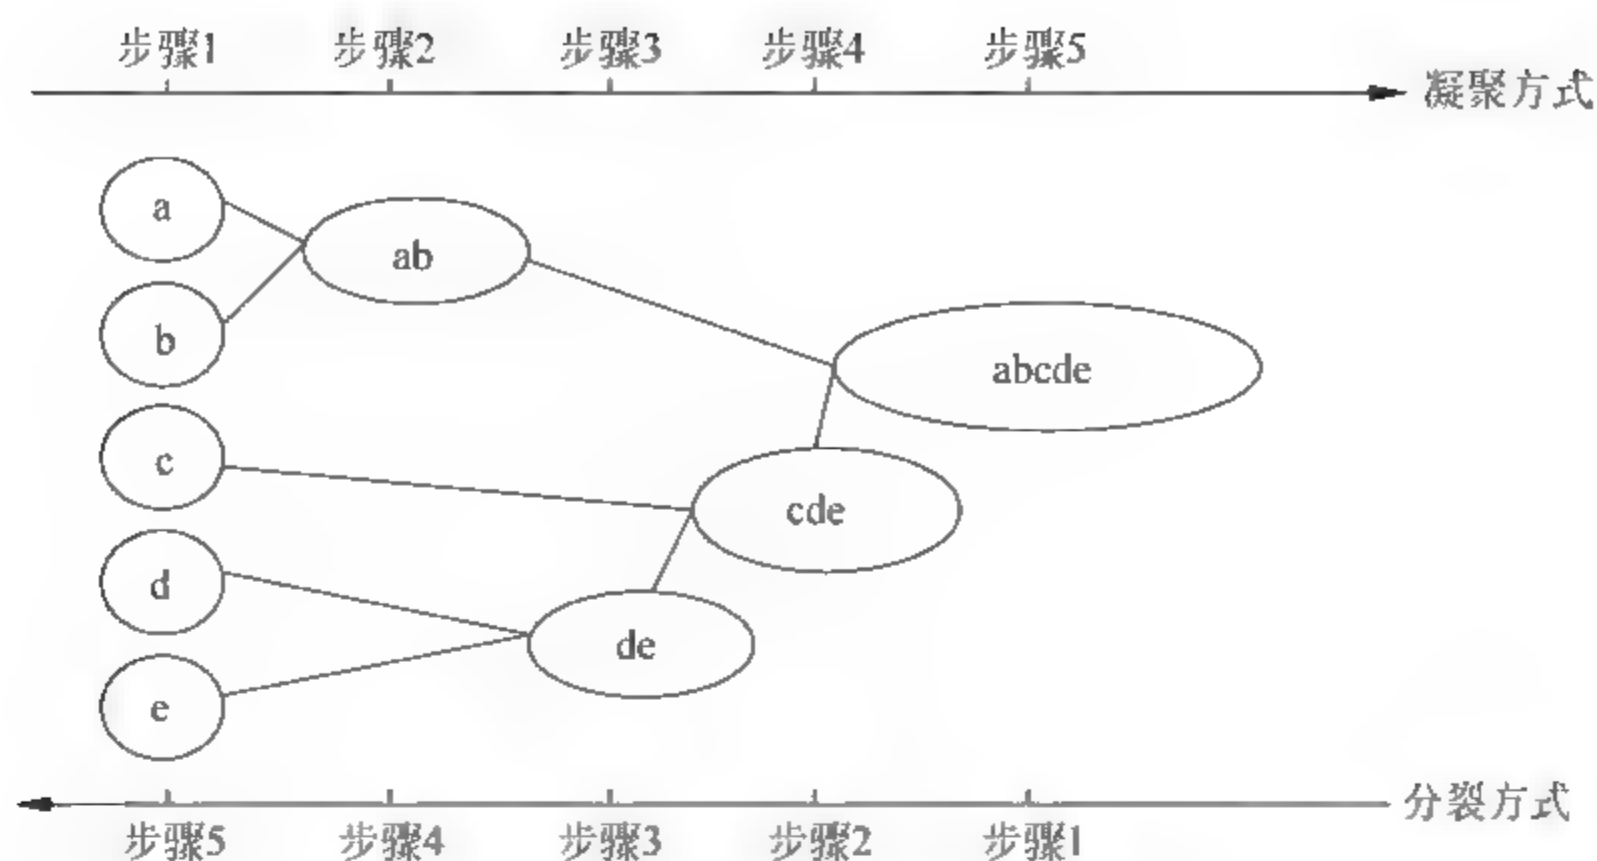


图 6.2 基于层次的聚类中的凝聚和分裂

代逐步将一个簇分裂为更小的簇。

根据不同的簇间距离度量方法,基于层次的聚类分为不同的种类,常用的距离度量方法包括最小距离、最大距离、平均值距离和平均距离等。

基于层次的聚类算法无需参数,但需要定义终止条件。其缺点是一旦一个步骤(凝聚或分裂)完成,则不能被撤销。CURE、Chameleon 和 BIRCH 等均为改进的基于层次的聚类算法。其中,Chameleon 是一种凝聚的层次聚类算法,算法实现包括两个阶段,即首先将数据集划分为多个子集,然后将这些子集进行反复的合并,直至获得最终的聚类结果,如图 6.3 所示。




图 6.3 CHAMELEON 算法示意图

CURE 算法如图 6.4 所示,其中  $s=50, p=2, s/p=25, q=5$ 。具体的算法步骤如下:

- (1) 随机选取  $s$  个样本。
- (2) 将所有样本划分为  $p$  个簇,每个簇样本数是  $s/p$ 。
- (3) 将每一簇划分为  $q$  个子集,每一子集样本数是  $s/pq$ 。
- (4) 删除孤立点数据。

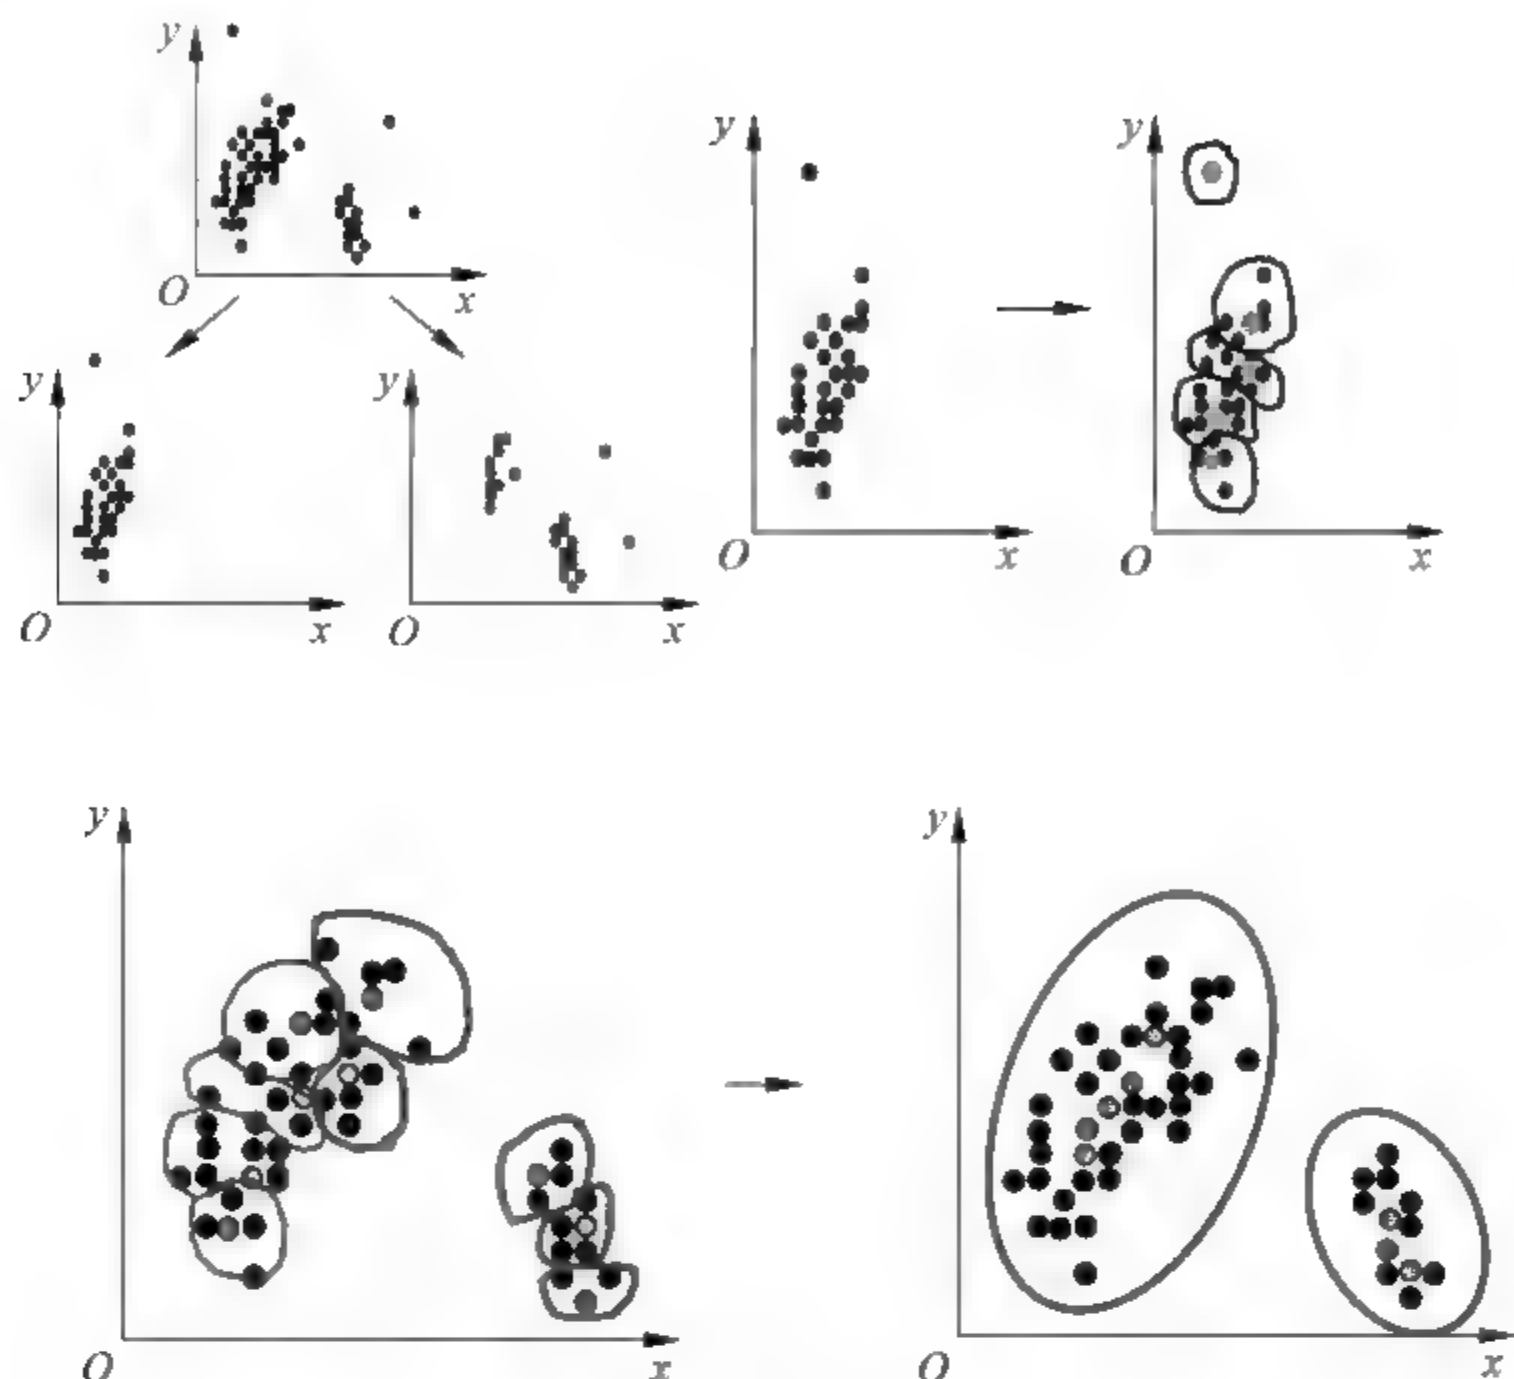


图 6.4 CURE 算法

- 随机取样；
- 如果一个簇变化缓慢，则删除该簇。

(5) 合并其中的部分子集。

基于层次的聚类算法适用于具有树枝状结构的数据集合。

### 3. 基于密度的聚类算法

这类算法的思想是只要某簇邻近区域的密度超过设定的阈值，则扩大簇的范围，继续聚类。这类算法可以得到任意形状的簇，典型算法包括 DBSCAN (Density based Spatial Clustering of Applications with Noise)、OPTICS 和 DENCLUE 等。

### 4. 基于网格的聚类算法

基于网格的聚类算法首先将问题空间量化为有限数目的单元，形成一个空间网格结构，随后聚类在这些网格之间进行。其特点是聚类速度较快，典型算法包括 STING、WareCluster 和 CLIQUE 等。

### 5. 基于模型的聚类算法

基于模型的聚类算法是指为每个簇假定一个模型，寻找数据对给定模型的最佳拟合。典型算法包括 COBWEB 和神经网络等。

上述算法均属于传统聚类的范畴。一般地，传统聚类算法对于维度较低的数据集有效，而当维度增加时，可能就不适用了。

针对大型数据库的聚类已提出了很多方法。例如，基于随机搜索的聚类方法 CLARANS、聚焦方法和聚类特征树法 BIRCH (平衡迭代消减聚类法) 等。CLARANS 要求待聚类的对象必须事先调入内存，这对于大型数据库不太适用；聚焦方法通过引入 R 树，能



够处理基于磁盘的大型数据库,但是R树的构造和维护代价太大;BIRCH则是一种较为灵活的递增式聚类方法,采用一个聚类特征三元组概括一簇对象的相关信息,从而以对应的聚类特征表示一簇对象而不是以具体的一组对象表示,通过构造满足分支因子和簇直径阈值的聚类特征树实现聚类。BIRCH算法需要提供适当的参数——聚类个数和簇直径阈值,这对于不具有可视化的高维数据是不可行的,而且对于一般的用户难以确定簇直径阈值。Agrawal提出的CLIQUE算法,利用自顶向下方法求出各个子空间的聚类单元。CLIQUE算法主要用于发现高维数据空间中存在的低维聚类,为了求出 $k$ 维空间的聚类,必须组合出所有 $k-1$ 维子空间的聚类,导致其算法的空间和时间效率都较低,而且要求用户输入数据空间等间隔距离和密度阈值两个参数,这些参数与样本数据紧密相关,一般用户难以确定。

### 6.1.2 相似度计算

在各种聚类算法中,数据对象之间特征差异通常是借助量化指标加以表征,称之为聚类统计量。聚类统计量主要包括:距离或相似度。

通常,数据对象采用矢量表示,即通过一个在多维空间中的矢量描述一个对象多方面的特征。矢量的每个维度描述对象的一个特征,多个对象的矢量构成一个模式矩阵(pattern matrix),其中每行代表一个对象,每列描述一个特征,即 $(x_{ij})_{nm}$ ,其中 $n$ 为对象数, $m$ 为特征数, $x_{ij}$ 为矢量特征值。由于不同的特征采用不同的度量标准,这将对聚类结果产生影响,为此通常需要进行正规化,使所有的特征能用一个共同的标准度量。以下是一些常用的正规化方法:

$$x'_{ij} = \frac{x_{ij}}{\max |x_{ij}|} \quad (6.1)$$

将所有的特征归一化到 $[-1,1]$ 区间。

标准差正规化

$$x'_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (6.2)$$

其中, $\mu_j = \frac{1}{n} \sum_{i=1}^n x_{ij}$ ,  $\sigma_j = \frac{1}{n} \sqrt{\sum_{i=1}^n (x_{ij} - \mu_j)^2}$ ,可使正态分布的特征取值主要集中在 $[-1,1]$ 区间。

$$x'_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (6.3)$$

其中, $\mu_j = \frac{1}{n} \sum_{i=1}^n x_{ij}$ ,  $\sigma_j = \frac{1}{n} \sum_{i=1}^n |x_{ij} - \mu_j|$ 。

与式(6.2)相比,具有更大的适用范围,因此受噪声的干扰较小。

极差正规化

$$x'_{ij} = \frac{x_{ij} - \min_{1 \leq j \leq n} \{x_{ij}\}}{\max_{1 \leq j \leq n} \{x_{ij}\} - \min_{1 \leq j \leq n} \{x_{ij}\}} \quad (6.4)$$

将所有特征归一化到 $[0,1]$ 区间。

正规化后,最常用的对象间距离计算公式包括:

(1) 欧氏距离,其定义为:

$$d_{ij} = \sqrt{|x_{i1} - x_{j1}|^2 + |x_{i2} - x_{j2}|^2 + \cdots + |x_{ip} - x_{jp}|^2} \quad (6.5)$$

其中, $i=(x_{i1}, x_{i2}, \cdots, x_{ip})$ 和 $j=(x_{j1}, x_{j2}, \cdots, x_{jp})$ 分别是两个 $p$ 维的数据对象。

(2) 曼哈顿距离(又称绝对距离),其定义为:

$$d_{ij} = |x_{i1} - x_{j1}| + |x_{i2} - x_{j2}| + \cdots + |x_{ip} - x_{jp}| \quad (6.6)$$

(3) 明考斯基距离,是欧氏距离和曼哈顿距离的概化,其定义为:

$$d_{ij} = \left[ \sum_{k=1}^n |x_{ik} - x_{jk}|^\gamma \right]^{1/\gamma} \quad (6.7)$$

其中 $\gamma > 0$ 。

$n$ 个对象彼此之间的相似度可通过相似度矩阵(similarity matrix) $(r_{ij})_m$ 表示,它是一个 $n \times n$ 维、对角线元素为1的对称矩阵,其中 $r_{ij}$ 是对象 $i$ 和 $j$ 之间相似度的量化表示,通常其值是非负的。对象 $i$ 和 $j$ 关系越亲密,其绝对值越接近于1;彼此关系越疏远,其值越接近于0。对象之间常用的相似度计算方法包括夹角余弦法、相关系数法和指数相似系数法等。

夹角余弦法

$$r_{ij} = \cos \alpha_{ij} = \frac{\sum_{k=1}^n x_{ik} x_{jk}}{\left( \sum_{k=1}^n x_{ik}^2 \sum_{k=1}^n x_{jk}^2 \right)^{1/2}} \quad (6.8)$$

其中, $\alpha_{ij}$ 为矢量 $i=(x_{i1}, x_{i2}, \cdots, x_{im})$ 和 $j=(x_{j1}, x_{j2}, \cdots, x_{jm})$ 之间的夹角。

相关系数法

$$r_{ij} = \frac{\sum_{k=1}^m |x_{ik} - \bar{x}_i| |x_{jk} - \bar{x}_j|}{\left[ \sum_{k=1}^m (x_{ik} - \bar{x}_i)^2 \sum_{k=1}^m (x_{jk} - \bar{x}_j)^2 \right]^{1/2}} \quad (6.9)$$

指数相似系数法

$$r_{ij} = 1/m \sum_{k=1}^m \exp \left[ -\frac{3}{4} \frac{(x_{ik} - x_{jk})^2}{S_k^2} \right] \quad (6.10)$$

为了实现自动聚类,首先定义相似度度量,无论采用哪种度量方法有一点是明确的,即相似度的度量与具体问题有关,给出通用的度量十分困难。例如,采用欧氏距离度量相似度的聚类是将聚类对象看做若干超球体的集合,适用于数据特征空间呈超球体的聚类。实际上,这一度量方法对于沿主轴分布的情况则是无用的甚至是不合理的。又如,实数集合的聚类结构表现为超椭圆体,因此对于数据分布呈超椭圆体的情况,常常采用马氏(Mahalanobis)距离,即:

$$D(x, m) = (x - m)^T \Sigma^{-1} x - m \quad (6.11)$$

其中, $\Sigma$ 是该聚类群体的协方差矩阵, $m$ 为平均矢量, $x$ 代表该聚类。

采用 Mahalanobis 距离的主要困难在于:每当改变某聚类范围时,都需要计算一次样



本协方差矩阵的逆。以 Mahalanobis 距离为相似度度量的自组织神经网络实现分布呈超椭球体的聚类(Hyper ellipsoidal Clustering, HEC)可减少计算量。HEC 分为两层:第一层由大量的主成分分析子网组成,以判断当前已形成的分布为超椭球体的聚类;第二层则是利用第一层所提供的聚类信息进行竞争学习。该方法不需要计算样本协方差矩阵的逆。但是,若学习参数选择不当,则实现主成分分析的子网达到收敛需要较长的时间。

### 6.1.3 实现方法

聚类的实现方法可概括为三种,即:

#### 1. 基于目标函数迭代的实现

在优化目标函数的过程中,人们曾经尝试动态规划、分支定界和凸切割等方法,然而大量的存储空间和运行时间限制了其应用。实际应用最为广泛的是 Dunn 提出的迭代优化算法——k 均值。本质上,迭代优化属于局部搜索的“爬山法”,易陷入局部极值,对初值也较敏感。

假设将  $n$  个样本  $x_j \in \mathfrak{R}^N (j=1, 2, \dots, n)$  划分为  $c$  类,对  $i=1, 2, \dots, c$  和  $j=1, 2, \dots, n$  可以定义:

$$\mu_{ij} = \begin{cases} 1, & \text{如果第 } j \text{ 个样本属于第 } i \text{ 类} \\ 0, & \text{其他} \end{cases} \quad (6.12)$$

则矩阵  $\mu=(\mu_{ij})$  具有如下性质:

$$\mu_{ij} \in \{0, 1\} \text{ 且 } \sum_{i=1}^c \mu_{ij} = 1, \quad j = 1, 2, \dots, n \quad (6.13)$$

设  $n_i$  表示第  $i$  类中所包含的样本个数,则

$$n_i = \sum_{j=1}^n \mu_{ij}, \quad i = 1, 2, \dots, c \quad (6.14)$$

设  $\bar{x}_i \in \mathfrak{R}^N$  是第  $i$  类的中心,则

$$\bar{x}_i = \frac{\sum_{j=1}^n \mu_{ij} x_j}{\sum_{j=1}^n \mu_{ij}} = \frac{1}{n} \sum_{j=1}^n \mu_{ij} x_j, \quad i = 1, 2, \dots, c \quad (6.15)$$

故第  $i$  类的类内差为:

$$S^{(i)}(\mu) = \sum_{j=1}^n \mu_{ij} \|x_j - \bar{x}_i\|^2 \quad (6.16)$$

整体类内差为:

$$S(\mu) = \sum_{i=1}^c S^{(i)}(\mu) = \sum_{i=1}^c \sum_{j=1}^n \mu_{ij} \|x_j - \bar{x}_i\|^2 \quad (6.17)$$

式(6.17)为经典的类内平方误差和(Within group Sum of Squared Error, WGSS)目标函数。k 均值旨在通过迭代优化寻找  $\mu_{ij}^*$ , 使得  $S(\mu)$  取最小值,即:

$$S(\mu_{ij}^*) = \min\{S(\mu)\} \quad (6.18)$$

由式(6.18)可知,当各样本独自成为一类时,即  $c=n$ ,  $S(\mu)$  取最小值 0。因此仅仅凭借

该目标函数是无法找到最优分类的,必须考虑其他条件,即寻找一个合适的目标函数。 $k$  均值是在给定  $c$  的前提下,优化  $S(\mu)$ 。因此,对聚类个数  $c$  而言,本质上是一种枚举法。

2. 基于神经网络的实现

采用神经网络实现聚类的显著优势在于神经网络的并行处理能力。因为在数据量庞大的情况下进行聚类相当耗时。

Kohonen 学习矢量量化和自组织特征映射在经典模式识别领域中的一个重要应用就是聚类。近年来,Kohonen 受到普遍关注,然而 Kohonen 聚类网络(Kohonen Clustering Network,KCN)启发式的演化过程使其在应用中存在着网络收敛依赖于输入样本顺序以及难以保证收敛等若干致命的问题。一些学者基于不同的角度和背景,提出了改进算法,但仍存在某些缺陷。后来,提出了一种用于超椭球体聚类的神经网络,它能自适应地估计每一类超椭球体形状,并将所得到的信息用于竞争学习,通过引入正规化的 Mahalanobis 距离,防止过大或过小类的产生。此外还提出了一种带惩罚项的竞争学习算法。

3. 基于进化计算的实现

进化计算是建立在生物进化基础上的基于自然选择和群体遗传机制的随机搜索算法。由于具有全局并行搜索的特点,因此可以较高的概率获得全局最优解。此外,进化计算还具有简单、通用和鲁棒性等优势。所以,人们将进化计算引入聚类,形成了一系列基于进化计算的聚类算法。它们大致可分为两类:一是基于模拟退火(Simulated Annealing,SA)的方法;二是基于遗传算法和进化策略的方法。

表 6.1 列出了上述三种聚类实现方法的比较。

表 6.1 三种聚类实现方法的比较

技 术 指 标	基于目标函数迭代的实现	基于神经网络的实现	基于进化计算的实现
搜索方法	梯度下降法	梯度下降法	随机搜索法
收敛速度	较快	快	慢
算法精度	高	较高	受编码长度的限制
算法结构	串行	并行	并行
初值敏感度	敏感	敏感	不敏感

6.1.4 主要算法

下面介绍硬聚类的一些主要算法。

1. 基于目标函数的聚类

基于目标函数的聚类主要包括  $k$  均值、 $k$  中心点和  $c$  均值等算法。

1)  $k$  均值

$k$  均值也称为硬  $c$  均值,该算法首先由 Mac Queen 提出,是一种基于划分而非分层的聚类方法。 $k$  均值的基本思想是:首先随机地选择  $k$  个对象,每个对象初始地代表一个簇的平均值或中心。对于其余的每个对象,根据其与其簇中心的距离,将它划分到最近的簇。然后重新计算每个簇的平均值。此过程不断迭代,直到目标函数(或称为相似度函数)收敛,即式(6.19)中的函数值最小。



$$E = \sum_{i=1}^k \sum_{p \in C_i} |p - m_i|^2 \quad (6.19)$$

式(6.19)中,  $E$  是所有对象的误差平方总和,  $m_i$  是簇  $C_i$  的平均值,  $p$  是空间中的点( $p$  和  $m_i$  都是多维的), 此目标函数试图使生成的簇尽可能地独立和紧凑。k 均值是将  $n$  个对象划分为  $k$  个簇, 使簇内的相似度较高, 而簇间的相似度较低。

k 均值聚类算法的步骤如下:

输入: 聚类数目  $k$ , 包含  $n$  个对象的数据集合

输出: 各对象属于  $k$  个簇的信息

- 1 随机选择  $k$  个对象作为初始的簇中心
- 2 将剩余的  $n - k$  个对象按照与簇中心的距离划分到最近的簇
- 3 Repeat
- 4     计算各个簇中对象各属性的平均值, 作为新的簇中心
- 5     重新将  $n$  个对象按照与簇中心的距离划分到最近的簇
- 6 Until 簇中心不再变化

k 均值是一种经典算法, 其主要优点是算法简单、快速而且能有效地处理大数据量。但是此算法对不同的初始值可能会导致不同的聚类结果, 执行结果与输入顺序有关。其次, 这种算法易陷入局部极小值。这两大缺陷大大限制了其应用范围。

## 2) k 中心点

k 中心点是对 k 均值的改进。不采用簇中对象的平均值作为参照点, 而是选用簇中位置最中心的对象, 即中心点。这样的划分方法依然是基于最小化所有对象与其参照点之间的相异度之和的原则进行的。

k 中心的基本思想是: 首先为每个簇随机地选取一个数据对象作为中心点, 将剩余的数据对象依照距离的远近分配给最近的簇; 随后选取其他的非中心点数据做中心点, 并查看聚类情况。如果替换的聚类总代价小于零, 则执行替换直到中心点不再发生变化, 即达到代价最小值时停止算法。

k 中心点聚类算法的步骤如下:

输入: 聚类数目  $k$ , 包含  $n$  个对象的数据集合

输出: 各对象属于  $k$  个簇的信息

- 1 随机选择  $k$  个对象作为初始的簇中心点
- 2 Repeat
- 3     将非中心点的对象依照与各簇中心点的距离划分到最近的簇
- 4     随机地在非中心点中选择一个对象
- 5     计算使用该点做中心点来代替原中心点的代价  $S$
- 6     If  $S < 0$  Then 用该点替换原中心点, 形成新的簇
- 7 Until 簇中心点不再发生变化

## 3) c 均值

c 均值聚类算法的步骤如下:

输入: 聚类数目  $k$ , 包含  $n$  个对象的数据集合

输出: 各对象属于  $k$  个簇的信息

- 1 随机选择  $k$  个对象作为初始的聚类中心  $c_1, c_2, \dots, c_k$

$$c_{im} = \frac{\sum_{x_i \in \text{cluster}_i} x_{i,m}}{N_i}$$



- 2 将每个对象的向量  $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]$ , 其中  $n$  为向量的维数, 按欧氏距离  $\|\mathbf{x}_i - \mathbf{c}_j\| = \min_j \|\mathbf{x}_i - \mathbf{c}_j\|$  归入聚类中心为  $\mathbf{c}_j$  的类
- 3 重新调整聚类中心  $\mathbf{c}_i$ , 令  $\mathbf{c}_i = [c_{i1}, c_{i2}, c_{in}]$ , 其中,  $N_i$  是第  $i$  个类别中的向量数
- 4 如果步骤 3 中的聚类中心不再变化, 则算法停止; 否则, 转至步骤 2

## 2. 基于神经网络的聚类

基于神经网络的聚类主要包括竞争学习(competitive learning)和自组织映射(Self Organizing Maps, SOM)等方法, 都涉及竞争的神经元。

### 1) 竞争学习

前馈神经网络的竞争式学习规则是由 Rumelhart 和 Zipser 提出的, 由若干个单元(神经元)组成层次结构, 以一种“胜者全取”实现竞争。竞争学习中各层之间的联接是激发式的, 即在某个给定层次的单元可以接受来自低一层次所有单元的输入, 在一层中活动单元的布局代表了高一层的输入模式。在某个给定层次中, 一个簇中的单元彼此竞争, 对低一层的输出模式做出反应。任何簇中只有一个单元是活跃的。获胜的单元修正其与簇中其他单元的连接权重, 以便在未来能够对与当前对象一样或相似的对象做出较强的反应。如果将权重看作一个标本, 那么新的对象将被划分到具有最近标本的簇。

聚类结束后, 每个簇被认为是一个新的“特征”, 代表对象的某些规律, 因此产生的簇可以看作一个低层特性向高层特性的映射。

### 2) SOM

SOM 是神经网络最重要的模型之一, 1982 年由 Kohonen 基于对生物神经活跃区域的模拟提出的。它是一种无监督的聚类方法, 通过反复学习和若干个单元的竞争实现聚类。权重向量最接近当前对象的单元成为活跃或获胜单元。为了更接近输入对象, 对获胜单元及其最近邻的权重进行调整。SOM 假设在输入对象中存在一些拓扑结构或顺序, 单元将最终在空间呈现这种结构。单元的组织形成一个特性映射。SOM 被认为类似于大脑的处理过程, 对在二维或三维空间中可视化高维数据是很有用的。

SOM 由输入层、竞争层和输出层组成。输入层结点的数目同输入对象的特征向量维度相同, 输出层的每个结点都是一个含有同输入层结点个数相同维度的向量。SOM 网络是全连接的, 每个输入结点都与所有的输出结点连接。

假定输入向量维度为  $N$ , 输出结点数为  $M$ 。SOM 算法的描述如下:

(1) 建立一个有  $M$  个输出结点的二维网格, 初始化从  $N$  个输入层结点到  $M$  个输出层结点的权值  $w_{ij}$  为  $[0, 1]$  之间的随机数;

(2) 输入  $N$  维的向量;

(3) 计算输入向量在时刻  $t$  到所有输出结点的距离, 即

$$d_j = \sum_{i=0}^{N-1} (x_i(t) - w_{ij}(t))^2 \quad (6.20)$$

其中,  $w_{ij}$  为输出结点的权值,  $x_i(t)$  是输入向量在时刻  $t$  的值;

(4) 选择获胜结点并更新它和邻近结点的权值。

选择产生最小  $d_j$  的结点为获胜结点  $j$ , 并更新其及邻近结点的权值以减小到输入向量  $x_i(t)$  的距离, 即:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t)(x_i(t) - w_{ij}(t)) \quad (6.21)$$



每次更新后,  $j$  及其邻近结点都会更接近输入向量  $x_i(t)$ 。 $\alpha(t)$  是误差调整系数,  $0 < \alpha(t) < 1$ , 并且随时间  $t$  单调减小,  $w_{ij}$  的调整也越来越小, 直至收敛。

SOM 以其无监督、可视化等特性, 广泛应用于聚类分析、图像处理、语音识别、组合优化和数据挖掘等众多领域。然而, 传统的 SOM 也存在许多不足, 其最大局限性是在学习样本量较少时, 网络连接权重的初始值对收敛性影响很大, 而且聚类效果取决于样本的输入顺序。

### 3. 基于进化计算的聚类

进化计算是建立在生物进化基础上的基于自然选择和群体遗传机制的随机搜索算法。由于具有全局并行搜索的特点, 因此可以较高的概率获得全局最优解。此外, 进化计算还具有简单、通用和鲁棒性等优势。所以, 人们将进化计算引入聚类, 形成了一系列基于进化计算的聚类算法。基于进化计算的聚类大致可分为两类: 一是基于模拟退火 (Simulated Annealing, SA) 的方法。确定性退火技术是美国的 K. Rose 博士于 1990 年首先提出的, 已得到了一些比较满意的理论结果。后来提出了一种利用确定性退火的启发式聚类算法, 把聚类问题看作是一个物理系统, 通过求解一系列随温度变化的自由能量函数的全局极小获得聚类的最优解。但是, 模拟退火算法只有当温度下降得足够慢时才能收敛到全局最优点, 大量的运算时间限制了其实用性; 二是基于遗传算法和进化策略的方法。

常用的进化算法和策略包括模拟退火、遗传算法、蚁群算法和粒子群优化算法等。

#### 1) 模拟退火

SA 算法的出发点是物理中固态物质的退火过程与一般组合优化问题之间的相似性。固态物质退火时, 通常先将之加温, 使其中的粒子能够自由移动, 然后逐渐降低温度, 粒子也逐渐形成低能态的晶格。若在凝结点附近温度的下降速度足够慢, 则固态物质一定会形成最低能量的基态。

SA 算法中固体状态对应组合最优问题的可行解, 最低能量的基态对应最优解, 逐渐降低温度的过程对应控制参数的下降。SA 首先由某一较高初始温度开始, 伴随温度参数的不断下降重复抽样, 最终获得问题的全局最优解。SA 包括一个温度持续下降的过程, 能够避免局部最小, 是一个基于概率的全局最优启发式方法。

在温度  $T$  时, 由当前状态  $i$  产生新状态  $j$ , 两者的能量分别为  $E_i$  和  $E_j$ 。若  $E_j < E_i$ , 则接受新状态  $j$  为当前状态; 否则, 若概率  $\exp\left(-\frac{E_j - E_i}{kT}\right)$  大于  $[0, 1)$  区间内的随机数, 则仍旧接受新状态  $j$  为当前状态; 若不成立, 则保留状态  $i$  为当前状态。 $\exp\left(-\frac{E_j - E_i}{kT}\right)$  中  $k$  为 Boltzmann 常量。这种方法使得能量为  $E_i$  的状态成为当前状态的概率是:

$$\frac{\exp(-E_i/kT)}{\sum_j \exp(-E_j/kT)} \quad (6.22)$$

这一概率函数称为 Boltzmann 浓度, 其特点是对于较高的温度, 每一状态都具有相同的概率成为当前状态, 而对于较低的温度, 仅仅那些低能量的状态才具有较高的概率成为当前状态。

标准 SA 算法的步骤如下:

- ① 随机产生一个初始状态  $S_0$ ,  $S_i = S_0$ , 令  $k = 0$ ,  $T_0 = T_{\max}$  (初始温度)。
- ② 若在该温度达到内循环停止条件, 则转步骤③; 否则, 从邻域  $N(x_i)$  中随机选一状态



$S_j$ , 若  $\Delta = E_j - E_i < 0$ , 则  $S_i = S_j$ ; 否则若  $\exp\left(-\frac{\Delta}{T_k}\right) > \text{random}[0,1]$  时, 则  $S_i = S_j$ ; 重复步骤②。

③ 退温  $T_{k+1} = d(T_k)$ ,  $k = k + 1$ ; 若满足终止条件, 停止计算; 否则转步骤②。

通常设  $T_{\max} = 100$ , 步骤③中的退温函数  $d(\cdot)$  可采用

$$T_{k+1} = \frac{T_k}{1 + \tau \sqrt{T_k}} \quad (6.23)$$

其中  $\tau$  为小时间常数。

SA 算法的优点体现在:

(1) 通用性强, 能够处理任何系统和费用函数, 即使对复杂问题 SA 的编码也相对容易。

(2) 通常可保证找到问题的全局最优解。普通的梯度下降算法总是向改进解的方向搜索, 这种“贪心”算法往往导致只能找到一个局部最优解, 而不是全局最优解。如图 6.5 所示, SA 算法中, 在系统能量减少这样一个总的趋势下, 允许偶尔向能量增加的方向搜索, 以避开局部极小, 最终能够稳定到全局最优状态。




图 6.5 梯度下降法与 SA 算法搜索空间的对比

SA 算法为寻找到最优解, 通常要求较高的初始温度、较慢的降温速率、较低的终止温度以及各温度下足够多次的抽样, 因而 SA 算法往往优化过程较长, 这是 SA 算法的不足之处。因此, 在保证一定优化质量的前提下提高算法的搜索效率, 是改进 SA 算法的主要途径。

## 2) 遗传算法

遗传算法 (Genetic Algorithm, GA) 由 Holland 在 1975 年提出的, 更早的思想可以追溯到 20 世纪 60 年代。典型的 GA 使用独立于问题的表示形式, 即二进制位串, 这种编码既适合变异又适合交叉, 并且强调交叉算子的搜索能力。随后, Holland 将 GA 引入到自适应系统, 后来又推广到其他领域。

GA 的进化对象是由多个个体 (individual) 组成的群体 (population)。在初始化后, 通过基于适应度的概率选择算法选择父代, 并通过交叉 (crossover) 和变异 (mutation) 维持群体的多样性。如此演化下去, 直到满足终止条件。

基于对自然界中生物遗传与进化机理的模仿, 针对不同的问题, 许多学者设计了多种不同的编码方法来表示问题的解空间, 设计了各种遗传算子模仿不同环境下的生物遗传特性。这样, 不同的编码方法和遗传算子就构成了各种遗传算法。但它们都具有共同的特点, 即通过模仿生物遗传和进化过程中的选择、交叉和变异等, 完成对问题最优解的自适应搜索过



程。基于这一共同特点,Goldberg 总结出了一种最基本的遗传算法——基本遗传算法(Simple Genetic Algorithm,SGA)或 CGA(Canonical GA)。SGA 只使用选择、交叉和变异三种算子,其遗传操作过程简单、容易理解,是其他一些遗传算法的基础和雏形,不仅给各种改进的遗传算法提供了一个基本框架,同时也具有一定的应用价值。

综上所述,遗传算法和其他进化算法相比的显著特征是使用交叉算子产生下一代个体;使用繁殖选择式的选择算子,根据适应度随机选取父本;一般使用二进制位串式编码及相应的交叉算子。

SGA 算法描述如下:

```

随机化初始群体  $P(0)$ ,  $t=0$ 
While(不满足终止条件) do
{
    计算所有个体的适应度
    计算每个个体的选择概率
    均匀随机选择  $p_g * N$  个个体,直接插入到下一代群体  $P(t+1)$  中
    for( $i=0$ ;  $i < (1-p_g) * N/2$ ;  $i++$ )
    {
        根据选择概率在  $P(t)$  中选择两个父本
         $r = \text{random}(0,1)$ 
        If  $r < p_c$ ,将两个父本不加改变地插入到下一代群体  $P(t+1)$  中
        Else
        {
            执行重组操作,产生两个子代
            按照变异概率  $p_m$  对两个子代执行变异操作
            将其插入到  $P(t+1)$  中
        }
    }
}

```

上述算法中包含四个基本参数,分别是代间隔  $p_g$ ,交叉概率  $p_c$ ,变异概率  $p_m$  和群体规模  $N$ 。

概括起来,SGA 的要素包括:

#### (1) 染色体编码方法

编码(coding)是将问题空间中的点映射到基因空间的过程。基因空间既可以二进制位串表示,也可以是空间  $R^n$  的一个子集。当基因空间的编码方式为位串时,也称为染色体(chromosome),其中的每一位称为基因(gene)。基因的取值范围称为等位基因(allele)。

编码方式决定了基因型和表现型之间的转换方法,某些特定的编码方法还决定了遗传算子的选择。编码的好坏在很大程度上决定了算法的优劣。

编码方案取决于具体的问题,因此目前尚没有一定的理论和评价原则。作为参考,De Jong 提出了两条操作性比较强的编码原则:一是有意义积木块原则,即使用能易于产生与所求问题相关的具有低阶、短定义长度的编码方案;二是最小字符集编码原则,即使用能使问题得到自然表示或描述的具有最小编码字符集的编码方案。

这两条原则具有一般的指导意义。随着时间的推移,使用的编码方式越来越丰富。在实际中,还需要考虑其他的原则。尤其是对于约束优化问题,一种方法是在编码时避免不合



法个体的存在,这样有可能造成编码和算子的复杂化与不一致性;另一种方法是针对不合法的个体,对其适应度加以惩罚。常用的编码方法如下:

① 位串编码。在进行编码时,将基因看做一个有序的位串序列,而不考虑每一位的含义。这种编码类似于生物染色体的组成,使交叉和变异等遗传操作很容易进行。

使用位串编码时,二进制编码可同时表示的模式数最多,并且实现简单,对于很多离散优化问题(如背包问题等),基因型与表现型的对应关系非常明确,因此得到广泛应用。

对于连续优化问题,二进制编码的主要问题是:相邻整数之间的 Hamming 距离可能很大,带来很多不必要的局部极值点,影响算法的搜索性能。这一问题也称为 Hamming 悬崖(Hamming Cliff)。

克服这一问题的一种方法是使用 Gray 编码。Gray 编码与二进制编码的对应关系如下:

设二进制串 $(\beta_1, \beta_2, \dots, \beta_{n-1}, \beta_n)$ 对应的 Gray 编码串为 $(\gamma_0, \gamma_1, \dots, \gamma_{n-1}, \gamma_n)$ ,则:

$$\gamma_k = \begin{cases} \beta_1, & k = 1 \\ \beta_{k-1} \oplus \beta_k, & \text{其他} \end{cases} \quad (6.24)$$

同样地

$$\beta_k = \begin{cases} \gamma_1, & k = 1 \\ \gamma_{k-1} \oplus \gamma_k, & \text{其他} \end{cases} \quad (6.25)$$

其中 $\oplus$ 表示模 2 加法,即异或操作。

Gray 编码的显著特点是对于距离为 1 的二进制表示,其 Gray 编码之间的 Hamming 距离为 1。因此可以在一定程度上克服上述缺点。

② 实数编码。当问题空间是实数连续空间时,可以直接采用实数进行编码。对于实数编码,从理论上讲,二进制编码的各种遗传操作都可以使用,但实际应用时通常都使用专门针对实数编码设计的算子。从进化计算的历史来看,进化策略和遗传规划都采用实数编码。近年来,遗传算法在求解复杂连续优化问题时也经常使用实数编码。实际上,使用实数编码的遗传算法和进化策略的区别已经越来越小。

③ 结构化编码。对于很多具有明确数据结构的问题,更加自然地表示是直接对这种数据结构进行操作,称之为结构化编码。常见的编码方式是树和图。这种编码方式一般是针对具体问题设计具体的编码和遗传算子,很难具有通用性。对于由 Koza 提出的遗传规划(genetic programming),可以看做是使用逆波兰表达式的二叉树作为结构化编码的进化算法的例子。

对于 SGA 最常用的是位串编码,即使用固定长度的二进制符号串表示群体中的个体,其等位基因是由二进制符号集 $\{0, 1\}$ 组成的。随机产生  $N$  个初始字符串,每个字符串称为一个个体, $N$  个个体构成一个初始群体。SGA 以  $N$  个个体为起点开始迭代。

## (2) 适应度函数

对于二进制位串空间 $\Omega = [0, 1]^l$ ,  $l$  称为染色体长度。称问题空间中的点为表现型(phenotype),基因空间中的点为基因型(genotype)。对于一个特定的基因型,其对应的表现型的优化函数值称为适应度(fitness)。

适应度函数表明个体对环境适应能力的强弱,是自然选择的唯一参考因素。



当欲求解的原始问题是数值优化问题时,可以直接将求解函数作为适应度。个体的适应度取值通常为正的实数值。一般情况下,当个体的性能越好时,其适应度值越大,而且要求非负(如GA中的比例选择策略)。因此,有时需要对原始的适应度函数进行变换。

当原始问题是非数值优化问题时,一种方案是选择恰当的度量函数充当适应度函数,将某个可行解的适应度变换到正实数空间;另外一种方案是使用不基于适应度函数具体数值的选择策略,如排名选择和锦标赛选择。

很多情况下,原始的适应度函数(及其简单变换)存在一些不适合选择使用的特点。有时适应度值之间的差别较小,导致选择效果不明显;有时优势个体的适应度值过大,可能产生早熟收敛。在这些情况下,需要对原始的适应度函数进行某种变换,以获得更好的性能。这种变换的具体形式通常是通过经验和试验获得的。

SGA算法按与个体适应度成正比的概率确定当前群体中每个个体遗传到下一代群体的机会。

### (3) 遗传算子

一般而言,各种进化算法的不同点在于产生新个体与选择的方式不同。这种方式也称为算子(operator)。进化算子可以分为两类:选择算子和演化算子。在有些算法的具体实现中,这两种算子往往混合在一起。

选择算子充当自然进化中自然选择的角色,起到指引搜索方向的作用。其目的是提高具有较高适应度的个体或其后代存活概率。通过选择算子,可以使群体向更高适应度的方向前进。不同的选择算子导致不同的选择压力(selection intensity)。选择压力较大,算法的收敛速度较快,但也容易导致早熟收敛。

选择算子按照选择阶段可分为繁殖选择和生存选择;按照比较范围可分为种群选择和生境选择;按照计算方式可分为确定性选择和概率性选择。繁殖选择指通过选择确定哪些个体可以用来产生下一代;生存选择指通过选择确定哪些个体可以存活。种群选择指选择是在整个种群的范围内进行的,个体的适应度要和整个种群的适应度分布进行比较。生境选择指选择是在两个或几个个体(通常具有血缘关系)之间进行的。确定性选择算子使用确定性的算法进行选择;而概率性选择算子在选择过程中引入随机性的因素。

演化算子充当自然进化繁殖过程中遗传和变异的角色,起到维护种群个体构成多样性(diversity)的作用。它包括交叉(crossover)和变异(mutation)两种。交叉算子又称重组(recombination)算子,用于从两个父本产生一个新的个体。演化算子在进化算法中起到构造的作用,可以从一个、两个或多个个体出发,构造出新个体。其目的是产生和维护群体的多样性,同时起到局部搜索的作用。

通常SGA使用以下三种遗传算子:

① 选择算子(selection operator)。一个群体中同时有 $N$ 个个体存在,这些个体哪个保留用于繁殖后代,哪个被淘汰,是通过选择过程实现的。选择的原则是适应度大的个体为下一代贡献一个或多个后代的概率较大。选择体现了“优胜劣汰”的原则。

常用的选择策略包括:

- 基于适应度比例的选择。
- 基于排名的选择(ranking selection)。

在使用基于适应度比例的选择策略时,会出现由于某些个体的适应度过大而导致的早



熟收敛。同时这种方式依赖于适应度函数的具体形式,对于某些应用而言,影响计算的收敛性和收敛速度。

基于排名的选择策略根据个体在整个群体中的适应度的好坏排名分配选择概率,可以避免上述问题。其基本形式是先根据所有个体的适应度进行排序,设排序后的次序为  $1, 2, \dots, N$ 。然后对于每一个体指定一个选择概率函数  $p_i$ 。 $p_i$  只与  $i$  有关,与  $f_i$  无关;且满足  $\sum_{i=1}^N p_i = 1, i$  单调递减。

常见的选择概率函数的形式包括线性排名和指数排名两种。

对于线性排名,有

$$p_i = \frac{1}{N} \left( a - \frac{2(a-1)i}{N+1} \right) \quad (6.26)$$

通常  $a=1.1$ 。

对于指数排名,有

$$p_i = \begin{cases} q(1-q)^{i-1}, & i < N \\ (1-q)^{N-1}, & i = N \end{cases} \quad (6.27)$$

基于排名的选择策略可以看作是对适应度函数的一种自适应变换,只不过这种变换是动态的,随着群体进化而变化,同时只和适应度的相对值有关,与绝对值无关。

#### • 基于局部竞争的选择。

以上两种方案都是根据个体在整个群体中的相对地位决定其选择概率,因此需要整个群体的信息。当群体规模很大时,需要一定的额外计算量,同时也不利于并行计算。基于局部竞争的选择策略可以在一定程度上解决这一问题。

锦标赛选择(tournament selection)通过随机选出的若干个个体之间进行竞争,适应度最大的个体获得优胜,并被选出产生其后代。

② 交叉算子(crossover operator)。对于选中用于繁殖的个体,随机选择位置,交换字符串左边部分,产生新个体,新个体继承了其父代的特性。交叉体现了信息交换的思想,它是算法的核心。

交叉算子的具体形式和基因的编码方式密切相关。对于位串编码,最简单的交叉算子是单点交叉,也有复杂一些的多点交叉和均匀交叉算子。

单点交叉的实现如下:随机地在两个父本上选择一个交叉点,然后交换这两个串对应的子串,得到的子代分别由父本连续的一部分构成。多点交叉则是随机生成多个交叉点,然后间断交换父本中对应的子串;均匀交叉则是依概率交换父串中的每一位。

对于这三种交叉算子,可以使用统一的形式化描述:

设两个父本为  $j_1$  和  $j_2$ ,存在一个交叉模板  $m$ ,交叉后的子代分别为:

$$s_1 = (j_1 \otimes m) \oplus (j_2 \otimes \bar{m}), \quad s_2 = (j_1 \otimes \bar{m}) \oplus (j_2 \otimes m) \quad (6.28)$$

式(6.28)中, $\otimes$ 、 $\oplus$ 和 $\bar{m}$ 分别表示二进制的与、异或和非运算。

如果  $m$  的结构是在某位之前都为 1,其后都为 0(或相反),则式(6.28)表示单点交叉;若  $m$  由连续的 0 串和 1 串混合而成,则表示多点交叉;而  $m$  的一般形式代表均匀交叉。

从模式的角度来看,多点交叉和均匀交叉能够搜索到的模式更多,具有更强大的搜索能



力。但实践证明,多点交叉和均匀交叉的作用并不显著。

对于其他类型的编码方式,可以设计出不同的交叉算子。在实际使用时,为避免致死基因(lethal gene),也需要对交叉算子进行改进。实际上,很多特定领域中使用的 GA 都要为之设计包含领域知识的交叉算子。

③ 变异算子(mutation operator)。变异操作是把某一个体的每一位按照概率取反。同生物界一样,GA 中发生变异的概率很低,通常取值在  $0.001 \sim 0.01$  之间。在二进制编码中,基本的变异方式就是将某一位或某几位进行反转。其形式化的描述如下:

设父代的二进制编码为  $j$ ,存在一个变异模板  $m$ ,变异后的结果为:

$$U(j) = j \oplus m \quad (6.29)$$

具体地,存在两种典型的变异方式,即 1 比特变异和  $c/l$  变异。

1 比特变异指按照变异概率确定待变异的个体后,均匀地从中选取一位进行反转,即模板中只有一位是 1;  $c/l$  变异指对于某一个体,每一位都按照概率  $p_m/l$  确定是否反转。一次变异有可能改变多位。

虽然这两种方式实现细节不同,但都具有遍历性,即从某个特定的基因型出发,经过有限次迭代可以达到任意的另一个基因型。

#### (4) 运行参数

SGA 算法有四个运行参数需要预先设定,即:

① 种群数目  $N$ : 种群数目影响 GA 的有效性。 $N$  太小,GA 会很差或根本找不到解,因为太小的种群数目不能提供足够的采样点;  $N$  太大,会增加运算量,使收敛时间过长。一般种群数目在  $50 \sim 200$  之间较为合适。

② 终止条件: 一般选择一定的进化代数或适应度函数值达到一定的阈值作为终止条件。

③ 交叉概率  $p_c$ : 它控制着交叉操作的频率,决定了个体的更新能力和算法在解空间的搜索能力。 $p_c$  太大,会使优良个体的破坏速度过大,造成算法性能不稳定;  $p_c$  太小,群体在进化过程中产生具有信息的新个体速度减慢,搜索会由于太小的探查率而可能停滞不前。一般  $p_c$  取值范围为  $0.25 \sim 0.75$ 。

④ 变异概率  $p_m$ : 它是增加群体多样性的算子。 $p_m$  太小,不会产生新的基因;  $p_m$  太大,会使 GA 退化成随机搜索。一般  $p_m$  取值范围为  $0.001 \sim 0.01$ 。

将 GA 应用于聚类有可能会带来一些问题,如编码冗余、对具体问题不敏感以及随机搜索最优解等。为了克服这些问题,可从编码方案、适应度函数、遗传算子和运行参数等几个方面对 SGA 算法加以改进。作为进化算法中最具有代表性的算法,遗传算法以其简单通用的编码和有效的进化操作得到了广泛的应用。目前遗传算法已经不再局限于二进制编码。最近很多的应用尝试使用其他的形式,如图、Lisp 表达式、有序列表和实数向量等。

#### 3) 蚁群算法

群体智能(Swarm Intelligence, SI)是一种人工智能技术,主要探讨由多个简单个体构成的群体的集体行为,这些个体之间相互作用,个体与环境之间也互为影响。尽管没有集中控制机制指导个体的行为,个体之间的局部交互也能够导致某一社会模式的出现。自然界中此类现象很多,如蚁群、鸟群、兽群和蜂群等,由这种自然现象引发的“群类算法”,如蚁群



算法、粒子群算法能够成功地解决现实中的优化问题。SI 与遗传算法具有共同之处,都是基于种群的,系统从一个由多个个体(潜在解)组成的种群开始,这些个体模仿昆虫或动物的社会行为代代繁殖,以寻求最优。不同于遗传算法的是,群体智能不使用交叉和变异这些进化算子,个体只是根据自身与群体中其他个体、与周围环境的关系不断地更新,以求得最优。

蚁群算法是模拟自然界蚂蚁觅食过程的一种分布式、启发式群体智能算法,最早是 1991 年由 Colormi、Dorigo 和 Maniezzo 提出,用于求解复杂的组合优化问题,如旅行商问题(TSP)、加工调度问题(JSSP)和图着色问题(GCP)等。

像蚂蚁这类群居昆虫,虽然单个个体的行为极为简单,但由这样的个体组成的蚁群却表现出极其复杂的行为,能够完成复杂的任务,不仅如此蚁群还能适应环境的变化,如在运动路线上遇到障碍物时,蚁群能够很快重新找到最优路径。那么蚁群是如何寻找最优路径的呢?

人们通过大量的研究发现,自然界中蚂蚁在觅食过程中沿途散播一种化学物质,称为信息素或外激素(pheromone),信息素中记录了食物源的远近与食物量的多少,而其他蚂蚁通过触角能够检测识别到这种信息素并跟踪,从而最终找到食物源。当大量蚂蚁不断地从蚁穴通往食物源,沿途不断地识别原有信息素,并同时散播新的信息素,使得越短的路线上的信息素浓度越高,最终找到一条最短的路线,此后所有的蚂蚁都将通过这条最短路径到达食物源。

如图 6.6(a)所示,假设从蚁穴到食物源有两条等长路线 NAF 和 NBF( $NAF=NBF$ )。初始时,两条路线上都没有信息素,各个蚂蚁随机选择其中一条路线,并沿途散播信息素。随着时间的推移,各路线会挥发掉部分信息素,也不断地增加新的蚂蚁带来的信息素,这是一个正反馈过程。后来的蚂蚁再选择路线时,浓度较高的路线被选择的概率较大。一段时间后,越来越多的蚂蚁会选择同一条路线,而另一条路线上的蚂蚁数量越来越少,且其上的信息素逐渐挥发殆尽。




图 6.6 蚂蚁觅食时最短路径选择

如图 6.6(b)所示,对于两条不等长的路线 NAF 和 NBF( $NAF>NBF$ )而言,初始时两条路线上都没有信息素,各个蚂蚁随机选择其中一条路线,即有些选择路线 NAF,另一些选择路线 NBF,并沿途散播信息素,两条路线上的蚂蚁数大致相等。假设蚂蚁的行走速度相同,则选择走路线 NBF(较短路线)的蚂蚁比选择走路线 NAF(较长路线)的蚂蚁先到达食物源 F;当走路线 NBF 的蚂蚁返回蚁穴时,走路线 NAF 的蚂蚁仍在途中 C 点处,即  $2NBF-NAF+FAC$ 。可以看出,线段 NC 上的信息素要少于别处;下次蚂蚁再选择路线时,会以较



高概率选择较短路径,这使得较长路线上的信息素浓度越来越低,较短路线上的信息素浓度越来越高。一段时间后,所有的蚂蚁都将选择较短的路线。

蚁群算法就是从蚂蚁觅食时寻找最短路径的现象中获得启示而设计的,由计算机编程实现的分布式并行搜索策略。蚂蚁通过别的蚂蚁留下来的信息素的强弱作为自己选择路径的参数,信息素越强的路径被选择的可能性越大。信息素的更新策略是越好的路径上获得的信息素越多,通过这个正反馈寻找更好的路径,这是蚁群算法的基本原理。单个蚂蚁的规则相当简单,但是通过蚁群的协同工作,产生对复杂环境的认知,实现对解空间的有效搜索。

蚂蚁觅食的过程与旅行商问题非常相似,下面以求解  $n$  个城市的 TSP 问题为例说明基本的蚁群算法。

首先设 TSP 中城市  $i$  与城市  $j$  之间的距离为  $d_{ij}$ ,  $m$  为蚁群中蚂蚁的数量,  $b_i(t)$  表示  $t$  时刻位于城市  $i$  的蚂蚁数量,则有  $m = \sum_{i=1}^n b_i(t)$ 。  $\tau_{ij}(t)$  表示  $t$  时刻弧  $(i, j)$  上的信息素量。初始时刻各弧上的信息素量相等,  $\tau_{ij}(0) = C$ ,  $C$  为常数。蚂蚁  $k$  在运动过程中,根据各弧上的信息素量决定移动的方向,  $p_{ij}^k(t)$  表示在  $t$  时刻蚂蚁  $k$  由点  $i$  向  $j$  移动的概率。

$$p_{ij}^k(t) = \begin{cases} \frac{\tau_{ij}^\alpha(t) \eta_{ij}^\beta(t)}{\sum_{j \in J_k(i)} \tau_{ij}^\alpha(t) \eta_{ij}^\beta(t)}, & j \in J_k(i) \\ 0, & \text{其他} \end{cases} \quad (6.30)$$

其中  $J_k(i)$  表示城市  $i$  上的蚂蚁  $k$  下一步允许选择的集合。  $\alpha$  和  $\beta$  分别表示蚂蚁在移动过程中所积累的信息素  $\tau_{ij}(t)$  及启发式因子  $\eta_{ij}(t)$  在蚂蚁择路时的重要程度。  $\eta_{ij}$  表示由城市  $i$  到城市  $j$  的期望值,可模拟某种启发式算法具体确定。另外,蚁群算法还具有记忆功能,用  $\text{tabu}_k (k=1, 2, \dots, m)$  记录蚂蚁  $k$  当前所走过的城市,集合  $\text{tabu}_k$  随进化过程进行动态调整。随着时间的推移,以前留下的信息素逐渐挥发,用参数  $1 - \rho$  表示信息素挥发程度,经过  $l$  个时刻,蚂蚁完成一次循环,各弧上的信息素量的调整如下所示:

$$\tau_{ij}(t+l) = \rho \cdot \tau_{ij}(t) + \Delta\tau_{ij} \quad (6.31)$$

$$\Delta\tau_{ij} = \sum_{k=1}^m \Delta\tau_{ij}^k \quad (6.32)$$

$\Delta\tau_{ij}^k$  表示第  $k$  只蚂蚁在本次循环中留在弧  $(i, j)$  上的信息素量,  $\Delta\tau_{ij}$  表示本次循环中弧  $(i, j)$  上的信息素的总增量。

$$\Delta\tau_{ij}^k = \begin{cases} \frac{Q}{L_k}, & \text{第 } k \text{ 只蚂蚁在本次循环中经过弧 } (i, j) \\ 0, & \text{其他} \end{cases} \quad (6.33)$$

其中,  $Q$  是常数,  $L_k$  表示第  $k$  只蚂蚁在本次循环中所走路径的总长度。

在此模型中,参数  $Q, C, \alpha, \beta, \rho$  通常由实验确定其最佳值。

基本蚁群算法求解 TSP 问题的主要步骤如下:

- ① 迭代次数  $nc=0$ ; 各  $\tau_{ij}$  和  $\Delta\tau_{ij}$  的初始化; 将  $m$  个蚂蚁置于  $n$  个顶点上。
- ② 将各蚂蚁的初始出发点置于当前解路线集中; 对每个蚂蚁  $k (k=1, 2, \dots, m)$  按式(6.30)的概率  $p_{ij}^k$  移至下一顶点  $j$ ; 将顶点  $j$  置于当前解路线集中。
- ③ 计算各蚂蚁的目标函数值  $Z_k$ ; 记录当前最佳解。
- ④ 按更新方程式(6.31)和式(6.32)修改轨迹强度。



⑤ 对各弧 $(i, j)$ , 置  $\Delta\tau_{ij} = 0, nc = nc + 1$ 。

⑥ 若  $nc < \text{预定迭代次数}$  且无退化行为(即找到的都是相同解), 则转至步骤②。

算法的时间复杂度为  $O(nc \cdot m \cdot n^2)$ 。就 TSP 问题而言, 经验结果是, 当  $m$  约等于  $n$  时效果最佳, 此时的时间复杂度为  $O(nc \cdot n^3)$ 。

蚁群算法的优点体现在:

- 较强的鲁棒性: 对基本蚁群算法稍加修改, 便可以应用于其他问题。
- 分布式计算: 蚁群算法是一种基于种群的进化策略, 具有并行性, 易于并行实现。
- 易于与其他方法结合: 蚁群算法很容易与多种启发式算法结合, 以改善算法性能。

研究证明蚁群算法具有很强的发现较好解的能力, 这是因为该算法不仅利用了正反馈原理, 在一定程度上可以加快进化过程, 而且是一种并行算法, 不同个体之间不断进行信息的交流和传递, 相互协作, 有利于发现较好解。

蚁群算法也存在一些缺陷, 例如:

- 搜索时间较长: 与其他算法相比, 一般需要较长的搜索时间, 其算法的复杂度体现在这一点。
- 易出现停滞现象: 当搜索到一定程度, 所有个体所发现的解完全一致, 不能对解空间进一步搜索, 不利于发现更好的解。

目前, 蚁群算法是继遗传算法、模拟退火、禁忌搜索、神经网络等热门算法之后, 新加入智能启发式算法这一行列的, 在短短的几年内受到越来越多的关注, 作为通用的随机优化方法, 通过其内在的搜索机制, 在一系列困难的组合优化问题求解中取得了成效。

#### 4) 粒子群优化算法

粒子群优化算法(Particle Swarm Optimization, PSO)最初由 Kennedy 和 Eberhart 于 1995 年提出, 是一种基于迭代的优化方法, 因其概念简单、实现容易迅速引起重视。目前已被应用于多目标优化、模式识别、信号处理和决策支持等领域。

PSO 最早源于对鸟群觅食行为的研究, 与蚁群算法同属于群体智能算法, 是从个体的社会行为中得到启发, 是对简单社会系统的模拟。PSO 算法中, 粒子群在一个  $n$  维空间中搜索, 其中每一个粒子所处的位置都表示问题的一个解。粒子通过不断调整其位置  $X$  搜索新的解。每个粒子都能记住自己搜索到的最好解, 记作  $P_{id}$ , 以及整个粒子群经历过的最好位置, 即目前搜索到的最优解, 记作  $P_{gd}$ 。每个粒子都具有一个速度, 记做  $V$ , 由式(6.34)计算:

$$V'_{id} = \omega \cdot V_{id} + \eta_1 \cdot \text{rand}() \cdot (P_{id} - X_{id}) + \eta_2 \cdot \text{rand}() \cdot (P_{gd} - X_{id}) \quad (6.34)$$

其中  $V_{id}$  表示第  $i$  个粒子第  $d$  维上的速度,  $\omega$  为惯性权重,  $\eta_1$  和  $\eta_2$  为调节  $P_{id}$  和  $P_{gd}$  相对重要性的参数,  $\text{rand}()$  为随机数生成函数。这样, 可以计算出粒子移动的下一位置是:

$$X'_{id} = X_{id} + V_{id} \quad (6.35)$$

从式(6.34)和式(6.35)可以看出, 粒子的移动方向由三部分决定, 自己原有的速度  $V_{id}$ 、与自己最佳经历的距离  $(P_{id} - X_{id})$  和与群体最佳经历的距离  $(P_{gd} - X_{id})$ , 并分别由权重系数  $\omega$ 、 $\eta_1$  和  $\eta_2$  决定其相对重要性。

标准 PSO 算法的描述如下:

① 初始化粒子群, 即随机设定各粒子的初始位置  $X$  和初始速度  $V$ 。



② 计算每个粒子的适应度值。

③ 对每个粒子,将其适应度值和它经历过的最好位置  $P_{id}$  的适应度值进行比较,如果更好,更新  $P_{id}$ 。

④ 对每个粒子,将其适应度值和群体所经历的最好位置  $P_{gd}$  的适应度值进行比较,如果更好,更新  $P_{gd}$ 。

⑤ 根据式(6.34)和式(6.35)调整粒子的速度和位置。

⑥ 如果达到结束条件(足够好的位置或最大迭代次数),则结束;否则转至步骤②。

PSO 是一种进化计算方法,具有以下进化计算的典型特征,即:

- 具有一个初始化过程,在这一过程中,群体中的个体被赋值为一些随机产生的初始解。
- 通过产生更好的新一代群体搜索解空间。
- 新一代群体产生在前一代的基础之上。

目前,PSO 算法在很多连续优化问题中获得较成功的应用,但是在离散域上的研究和应用还很少。

## 6.2 模糊聚类

### 6.2.1 概述

通常地,硬聚类是指将包含  $n$  个对象的集合划分为  $k$  个互斥的类,聚类结果可表示为一个  $n \times k$  的矩阵  $U = (u_{ik})$ ,若对象  $i$  属于类  $k$ ,则  $u_{ik} = 1$ ; 否则  $u_{ik} = 0$ 。为保证各类是分离的且非空,  $u_{ik}$  必须满足下列条件:

$$\begin{aligned} \sum_{k=1}^K u_{ik} &= 1, \quad i = 1, 2, \dots, n \\ \sum_{i=1}^n u_{ik} &> 0, \quad k = 1, 2, \dots, K \end{aligned} \quad (6.36)$$

其中,  $u_{ik} \in \{0, 1\}$   $i = 1, 2, \dots, n; k = 1, 2, \dots, K$ 。

实际上,互斥的聚类在实际中并不适合,因此提出了模糊聚类,它与硬聚类的本质区别在于:

$$u_{ik} \in [0, 1] \quad i = 1, 2, \dots, n; k = 1, 2, \dots, K \quad (6.37)$$

模糊聚类(Fuzzy Clustering Analysis, FCA)是指一个对象以不同程度属于多个类,各类之间的界限是不确定的。其本质是不仅要考虑对象是否属于该类,而且要考虑属于该类的程度如何。模糊聚类完全不同于所谓的硬聚类,即类别之间的界限是明确而严格的。

1966 年, Bellman、Kalaba 和 Zadeh 首先提出以模糊集为基础实现聚类。其后, Wee、Flake、Turner 及 Gitman 和 Levine 等人进行了一些尝试性探索,系统地阐述模糊聚类算法的是著名学者 Ruspini。20 世纪 70 年代到 80 年代,人们对模糊矩阵及其传递闭包等问题进行了大量研究。到 90 年代,尽管仍有人从事这一方面的研究,但由于这类方法不适用于



大型数据集,所以日渐冷落。后来人们试图用图论的方法研究模糊聚类,1993年 Zhenggu Wu 和 Leathy 提出最优图论的聚类方法。在将硬聚类推广到模糊聚类方面也进行了大量工作,如将  $k$  最近邻推广到模糊聚类;1986年 Bezdek 等人将模糊  $c$  均值应用到  $k$  最近邻,提出了一种模糊  $k$  最近邻法。此外还提出了其他一些模糊聚类方法,如1987年 Bezdek 和 Harri 利用数据集的凸分解进行模糊聚类。

由于种种原因,上述方法的应用并不广泛。实际中,受到普遍关注的是基于目标函数的模糊聚类如模糊  $c$  均值等。

基于目标函数的模糊聚类算法首先是由 Ruspini 提出的,随后其一般化方法——模糊  $c$  均值及其收敛性被提出并加以证明。从此,基于目标函数的模糊聚类方法得以迅速发展,目前已形成了庞大的体系。它是近年来发展很快的一种聚类方法。其目的是使用模糊系统解决客观世界中存在的界限不分明的聚类问题,对样本进行合理的模糊划分,从而达到判别、分析与预测的目的。

模糊聚类的研究工作大致可分为两类,即:

(1) 通过模糊方法得到模糊结果,每个模式以不同的隶属度从属于若干个类。以 Bezdek 提出的模糊  $k$  均值为代表,该算法收敛于部分最优,存在局部极值问题。Al. Sultan 等人采用模拟退火算法使结果收敛于全局最优,它们均为迭代算法。

(2) 通过模糊方法得到确定的结果,每个模式仅从属于特定的类,如 Miyamoto 等人提出的算法,需要反复计算分类对象之间的模糊相似度。

目前,有关模糊聚类的研究大多是对模糊  $c$  均值的推广与改进。

大致地,模糊聚类算法包括系统聚类法、传递闭包法、最小支撑树(如 Prim 和 Kruskal 算法)、动态直接聚类法、模糊  $c$  均值和人工神经网络等。

模糊聚类中,对象对各个类的隶属度值介于  $[0,1]$  区间。模糊聚类考虑到了对象之间的联系,认为每一对象与各聚类中心都存在着一定的隶属关系。模糊聚类能够有效地对类与类之间存在交叉的数据集进行聚类,所得到的聚类结果明显优于传统聚类。一般地,模糊聚类要求每一对象对各类的隶属度之和为 1,这一约束是对划分情况的概率约束。但是,这一约束无法反映对象的典型性,对含有噪声的数据集聚类很不理想。与传统聚类算法相比,通常模糊聚类算法的收敛速度要慢。

模糊聚类方法已被广泛应用到数据挖掘、模式识别、机器学习以及决策支持等领域。例如可依据“体重/身高”,把人分成“胖人集”、“不胖不瘦集”和“瘦人集”等;对超市可根据“月底销售数量/月初库存”,确定出“畅销商品集”与“滞销商品集”,并进一步分析在同一类别内的商品之间的销售相关性以支持营销决策等。此外,模糊聚类还可以应用到对多维图像的识别与分割、天然中草药分类等。

设数据对象集合为  $X = \{x_1, x_2, \dots, x_n\}$ ,  $\forall x_i \in X$ , 其样本  $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$ ,  $x_k$  表示第  $i$  个对象的第  $k$  个属性。模糊相似矩阵(Fuzzy Dissimilarity Matrix)  $(r_{ij})_{n \times n}$  用于存储  $n$  个对象彼此之间的模糊相似度,是一个  $n \times n$  维的对角线元素为 1 的对称矩阵,即:



$$\begin{bmatrix} 1 & & & & \\ r_{21} & 1 & & & \\ r_{31} & r_{32} & 1 & & \\ \vdots & \vdots & \vdots & \ddots & \\ r_{n1} & r_{n2} & r_{n3} & \cdots & 1 \end{bmatrix} \quad (6.38)$$

常用的计算模糊相似度的方法包括:

(1) 数量积法

$$r_{ij} = \begin{cases} 1, & i = j \\ \frac{1}{M} \sum_{k=1}^m x_{ik} x_{jk}, & i \neq j \end{cases} \quad (6.39)$$

其中,  $M = \max_{i \neq j} \left( \sum_{k=1}^m x_{ik} x_{jk} \right)$ 。如果  $r_{ij}$  为负值, 可用式(6.40)修正。

令

$$r'_{ij} = \frac{r_{ij} + 1}{2}, \quad \text{则 } r'_{ij} \in [0, 1] \quad (6.40)$$

(2) 夹角余弦法

$$r_{ij} = \frac{\sum_{k=1}^m x_{ik} x_{jk}}{\sqrt{\sum_{k=1}^m x_{ik}^2} \sqrt{\sum_{k=1}^m x_{jk}^2}} \quad (6.41)$$

(3) 统计相关系数法

$$r_{ij} = \frac{\sum_{k=1}^m (x_{ik} - \bar{x}_i)(x_{jk} - \bar{x}_j)}{\sqrt{\sum_{k=1}^m (x_{ik} - \bar{x}_i)^2} \sqrt{\sum_{k=1}^m (x_{jk} - \bar{x}_j)^2}} \quad (6.42)$$

其中,

$$\bar{x}_i = \frac{1}{m} \sum_{k=1}^m x_{ik}, \quad \bar{x}_j = \frac{1}{m} \sum_{k=1}^m x_{jk}$$

(4) 最大最小法

$$r_{ij} = \frac{\sum_{k=1}^m (x_{ik} \wedge x_{jk})}{\sum_{k=1}^m (x_{ik} \vee x_{jk})} \quad (6.43)$$

(5) 算术平均法

$$r_{ij} = \frac{2 \sum_{k=1}^m (x_{ik} \wedge x_{jk})}{\sum_{k=1}^m (x_{ik} + x_{jk})} \quad (6.44)$$

### (6) 几何平均最小法

$$r_{ij} = \frac{\sum_{k=1}^m (x_{ik} \wedge x_{jk})}{\sum_{k=1}^m \sqrt{x_{ik} x_{jk}}} \quad (6.45)$$

### (7) 绝对值指数法

$$r_{ij} = e^{-\sum_{k=1}^m |x_{ik} - x_{jk}|} \quad (6.46)$$

### (8) 指数相似系数法

$$r_{ij} = \frac{1}{m} \sum_{k=1}^m e^{-(x_{ik} - x_{jk})^2} \quad (6.47)$$

### (9) 绝对值倒数法

$$r_{ij} = \begin{cases} 1, & i = j \\ \frac{M}{\sum_{k=1}^m |x_{ik} - x_{jk}|}, & i \neq j \end{cases} \quad (6.48)$$

适当选取  $M$ , 使  $r_{ij} \in [0, 1]$ 。

### (10) 绝对值减数法

$$r_{ij} = 1 - c \sum_{k=1}^m |x_{ik} - x_{jk}| \quad (6.49)$$

适当选取  $c$ , 使  $r_{ij} \in [0, 1]$ 。

## 6.2.2 主要算法

下面介绍几种主要的模糊聚类算法。

### 1. 模糊 $c$ 均值

目前, 模糊聚类算法中应用最广泛而且较成功的是 1974 年由 Dunn 提出并由 Bezdek 加以推广的模糊  $c$  均值(Fuzzy  $c$ -means, FCM)。

假设待聚类样本数为  $n$ , 聚类数为  $c$ , 特征数为  $s$ , 则有如下定义:

**定义 6.1** 样本集  $X = \{x_1, x_2, \dots, x_n\}$  是任一有限集,  $X \subset R^s$ ,  $V_{cn}$  是  $c \times n$  阶实矩阵的集合,  $c$  是整数 ( $2 \leq c < n$ ), 则称下述集合为  $X$  的模糊  $c$  均值划分空间:

$$M_{fc} = \left\{ U \in V_{cn} \mid 0 \leq u_{ik} \leq 1, \forall i, k; \sum_{i=1}^c u_{ik} = 1, \forall k; 0 \leq \sum_{k=1}^n u_{ik} < n, \forall i \right\} \quad (6.50)$$

其中  $u_{ik}$  是隶属度矩阵  $U \in M_{fc}$  的  $i$  行  $k$  列元素, 表示  $x_k$  对于类  $i$  的隶属度值。

**定义 6.2** 设  $v_i \in R^s$  是类别  $i$  的聚类典范值(中心)矢量, 定义  $c$  聚类典范值矩阵为:

$$V = (v_1, v_2, \dots, v_c)^T \quad (6.51)$$

模糊  $c$  均值的目标函数  $J_m$  定义为:

$$J_m(U, V) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m (d_{ik})^2 \quad (6.52)$$



其中  $(d_{ik})^2 = \|x_k - v_i\|^2$ ,  $\|\cdot\|$  是  $R^s$  上任一内积导出的范数;  $m$  是加权指数,  $m \in [1, \infty)$ 。

目标函数的值是样本数据到  $c$  聚类典范值的平方距离的加权累计和, 权重由  $m$  和模糊隶属度函数值共同确定。  $J_m$  反映在某种差异性定义下的类内紧致度。  $J_m$  越小, 聚类越紧致; 而  $m$  越大, 紧致度的模糊性越大, 因为  $m$  控制隶属度在各类之间共享的程度。

FCM 算法步骤如下:

① 设定迭代停止阈值  $\epsilon_L$  为一小正数; 初始化迭代次数为  $l=0$  和  $U^{(0)}$ ;

② 将  $U^{(l)}$  代入式(6.51)计算  $c$ -聚类典范值矩阵  $V^{(l)}$ :

$$v_i = \frac{\sum_{k=1}^n (u_{ik})^m x_k}{\sum_{k=1}^n (u_{ik})^m}, \quad \forall i \quad (6.53)$$

③ 利用  $V^{(l)}$  更新  $U^{(l)}$ , 其过程如下:

$\forall$  样本  $x_k$ , 计算类别标号的集合:  $I_k = \{i | 1 \leq i \leq c; d_{ik} = 0\}$  和  $\tilde{I}_k = \{1, 2, \dots, c\} - I_k$ 。

如果  $I_k = \phi$ , 则

$$u_{ik} = \frac{1}{\sum_{j=1}^c (d_{ik}/d_{jk})^{2/(m-1)}} \quad (6.54)$$

否则

$$u_{ik} = 0, \quad \forall i \in \tilde{I}_k, \quad \text{且} \sum_{i \in \tilde{I}_k} u_{ik} = 1 \quad (6.55)$$

选用合适的矩阵范数比较  $U^{(l)}$  和  $U^{(l+1)}$ , 如果  $\|U^{(l+1)} - U^{(l)}\| \leq \epsilon_L$ , 则停止迭代; 否则  $l = l+1$ , 转至步骤②。

FCM 算法中, 模糊指数  $m$  的取值是关键。  $m$  值越大, 聚类的范围越大, 隶属度函数的模糊程度越大。当  $m$  趋近 1 时, FCM 相当于硬  $c$  均值, 所以  $m$  不应该趋近 1。目前还没有发现确定合适  $m$  值的方法。根据经验一般取  $1.1 \leq m \leq 5$ 。Pal 等人从聚类有效性方面研究得到  $m$  的最佳取值范围是  $[1.5, 2.5]$ , 且一般  $m=2$ 。

FCM 的本质是使聚类中所有样本到聚类中心的距离平方和最小。通过优化模糊目标函数得到每个样本对类中心的隶属度。但是, FCM 有时会收敛到局部极小值, 这限制了 FCM 算法的应用。

## 2. 模糊关系传递闭包

设有  $n$  个样本  $U = (x_1, x_2, \dots, x_n)$ , 其中每个样本具有  $m$  个特征, 即  $x_i = (x_{i1}, x_{i2}, \dots, x_{im})$ 。利用多元分析方法建立样本之间的模糊关系  $R: U \times U \rightarrow [0, 1]$ ,  $(x_i, x_j) \in R$  的程度通常用隶属度函数  $\mu_R(x_i, x_j)$  表示,  $\mu_R(x_i, x_j)$  被称为  $x_i$  和  $x_j$  的相似值, 满足  $0 \leq \mu_R(x_i, x_j) \leq 1$ ,  $\mu_R(x_i, x_j) = \mu_R(x_j, x_i)$ 。  $\mu_R(x_i, x_j)$  越大, 两者的相似度越高, 定义  $\mu_R(x_i, x_i) = 1, i = 1, 2, \dots, n$ 。模糊关系的确定方法采用距离法, 例如切比雪夫距离  $\mu_R(x_i, x_j) = 1 - c \max_{1 \leq k, j \leq m} |x_{ik} - x_{jk}|$ , 其中  $c$  表示一个常数, 或海明距离、欧氏距离和相似系数等。由  $n$  个样本之间的模糊关系形成一个  $n \times n$  矩阵  $R = (\mu_R(x_i, x_j))_{n \times n}$ , 称  $R$  为模糊相似矩阵。

设  $U, V$  和  $W$  分别表示三个论域, 若  $R, S$  分别为  $U \times V$  和  $V \times W$  上的模糊关系, 定义关系的合成  $R \circ S$  为  $U \times W$  上的模糊关系, 其隶属度函数定义为:

$$\mu_{R \circ S}(x, z) = \{\max_{y \in V} \{\min[\mu_R(x, y), \mu_S(y, z)]\}\} \quad (6.56)$$

其中,  $\forall x \in U, \forall z \in W$ 。

若  $R$  是  $U$  上的模糊关系, 并满足  $R \circ R \subseteq R$ , 则称  $R$  为模糊传递矩阵。

若模糊相似矩阵  $R$  满足传递性, 则称  $R$  为等价关系。对任意的  $\alpha \in [0, 1]$ , 集合  $R_\alpha = \{(x, y) \mid \mu_R(x, y) \geq \alpha\}$  称为  $R$  的  $\alpha$  截集,  $\alpha$  称为截集阈值。若  $R$  为模糊等价关系, 则对任意  $\alpha \in [0, 1]$ ,  $R_\alpha$  也为模糊等价关系, 有时称  $R_\alpha$  为  $\alpha$  截矩阵。若  $R_\alpha$  为等价矩阵, 则  $\forall x \in U$ ,  $[x] = [y \mid \mu_R(x, y) \geq \alpha]$  构成  $U$  相对于阈值  $\alpha$  的模糊聚类。

模糊相似矩阵  $R$  的传递闭包是指包含  $R$  的最小模糊等价矩阵。利用平方法可以求得模糊相似矩阵的传递闭包。

**定理 6.1** 设  $R$  为  $n$  阶模糊相似矩阵, 则存在一个最小自然数  $k (k < n)$ , 使得传递闭包  $t(R) = R^k$ , 且对一切大于  $k$  的自然数  $L$  恒有  $R^L = R^k$ 。

定理 6.1 说明从模糊相似矩阵  $R$  开始, 利用平方依次计算  $R^2, R^4, R^8, \dots$  直到出现  $R^k \cdot R^k = R^k$  时,  $R^k$  就是传递闭包  $t(R)$ 。设  $R$  和  $S$  为模糊相似矩阵,  $R = (r_{ij})_{n \times n}, S = (s_{ij})_{n \times n}$ , 则

$$R \cdot S = (t_{ij})_{n \times n}, \text{ 其中, } t_{ij} = \bigvee_{k=1}^n (r_{ik} \wedge s_{kj}).$$

基于模糊关系传递闭包的模糊聚类算法的步骤如下:

- ① 确定集合  $X = \{x_1, x_2, \dots, x_n\}$  上模糊相似矩阵  $R$  和一个截集阈值  $\alpha$ 。
- ② 采用自乘法将  $R$  按如下计算构造为一个模糊等价矩阵:

$$\begin{aligned} R \cdot R &= R^2 \\ R^2 \cdot R^2 &= R^4 \\ &\vdots \end{aligned}$$

直到存在  $k$ , 满足  $R^{2k} = R^k$ , 则  $R^k$  即为一个模糊等价矩阵。

- ③ 计算模糊等价矩阵的  $\alpha$  截矩阵  $R_\alpha = (r_{ija})_{n \times n}$ , 且

$$r_{ija} = \begin{cases} 1, & r_{ij} \geq \alpha \\ 0, & r_{ij} < \alpha \end{cases}$$

- ④ 输出模糊聚类结果, 即将  $\alpha$  截矩阵中相同行的样本归为一类, 表示为

$$[x] = \{y \mid R^k(x, y) \geq \alpha\}$$

- ⑤ 若满足聚类终止条件, 则停止; 否则, 改变截集阈值  $\alpha$ , 转至步骤②。

该算法中将模糊相似矩阵改造成模糊等价矩阵采用自乘法, 计算时间较长, 其时间复杂度为  $O(n^3 \log_2 n)$ 。

### 3. 最小支撑树

最小支撑树算法的步骤如下:

- ① 建立模糊相似矩阵
- ② 构建最小支撑树
- ③ 聚类



典型的最小支撑树算法包括 Prim 算法和 Kruskal 算法。

设待聚类对象集合为 $\{1, 2, 3, 4, 5\}$ , 给定如下的模糊相似矩阵:

$$R = \begin{bmatrix} 1 & & & & \\ 0.1 & 1 & & & \\ 0.8 & 0.1 & 1 & & \\ 0.5 & 0.2 & 0.3 & 1 & \\ 0.3 & 0.4 & 0.1 & 0.6 & 1 \end{bmatrix}$$

### 1) Prim 算法

① 先取对象 1, 在对象 2、3、4 和 5 中, 找出与 1 相似度最大的, 可得

$0.8 = R(1, 3)$ , 即:

$$1 \xrightarrow{0.8} 3$$

在对象 2、4 和 5 中, 找到与对象 1 相似度最大的  $0.5 = R(1, 4)$ , 找出与对象 3 相似度最大的  $0.3 = R(3, 4)$ , 因  $0.5 > 0.3$ , 取对象 4, 得到:

$$4 \xrightarrow{0.5} 1 \xrightarrow{0.8} 3$$

然后在对象 2 和 5 中, 找出与对象 1、3 和 4 相似度最大的  $0.6 = R(4, 5)$ , 得到:

$$5 \xrightarrow{0.6} 4 \xrightarrow{0.5} 1 \xrightarrow{0.8} 3$$

最后, 找出对象 2 与 1、3、4 和 5 之间相似度最大的  $0.4 = R(2, 5)$ , 得最小支撑树, 即:

$$2 \xrightarrow{0.4} 5 \xrightarrow{0.6} 4 \xrightarrow{0.5} 1 \xrightarrow{0.8} 3$$

② 取  $\lambda \in [0, 1]$ , 砍断连接权重小于  $\lambda$  的枝, 可以得到一个不连通的图, 而各连通分支就构成了  $\lambda$  水平上的分类。

若取  $\lambda \in [0, 0.4]$ , 则只得一类  $\{1, 2, 3, 4, 5\}$ ; 若取  $\lambda \in (0.4, 0.5)$ , 则得两类  $\{2\}$ 、 $\{1, 3, 4, 5\}$ ; 若取  $\lambda \in (0.5, 0.6)$ , 则得到三类  $\{2\}$ 、 $\{4, 5\}$  和  $\{1, 3\}$ ; 若取  $\lambda \in (0.6, 0.8)$ , 则得四类  $\{2\}$ 、 $\{5\}$ 、 $\{4\}$  和  $\{1, 3\}$ ; 若取  $\lambda \in (0.8, 1)$ , 则得五类  $\{1\}$ 、 $\{2\}$ 、 $\{3\}$ 、 $\{4\}$  和  $\{5\}$ 。

### 2) Kruskal 算法

① 首先在  $R$  的非主对角线中找到最大元  $0.8 = R(1, 3)$ , 得到:

$$3 \xrightarrow{0.8} 1$$

再找次最大元  $0.6 = R(4, 5)$ , 得到:

$$3 \xrightarrow{0.8} 1 \quad 4 \xrightarrow{0.6} 5$$

然后找到  $0.5 = R(1, 4)$ , 得到:

$$3 \xrightarrow{0.8} 1 \xrightarrow{0.5} 4 \xrightarrow{0.6} 5$$

最后得到  $0.4 = R(2, 5)$ , 至此所有顶点都被连到, 且不含圈, 得到最小支撑树, 即:

$$3 \xrightarrow{0.8} 1 \xrightarrow{0.5} 4 \xrightarrow{0.6} 5 \xrightarrow{0.4} 2$$

② 同 Prim 算法中的步骤②。

采用上述两种方法所得的最小支撑树可能不同, 但可以证明其聚类结果相同。其中, Prim 算法的复杂度最多为  $O\left(\frac{3n^3}{2}\right)$ , Kruskal 算法的复杂度最多为  $O(n^3 \log_2 n)$ 。

## 6.3 评价

聚类分析是一种无监督的学习,事先对给定数据集合的结构一无所知,没有利用任何先验知识。无论采用哪种聚类算法,其聚类结果的合理性和有效性都有待评价。聚类有效性评价对聚类分析具有重要意义。对于相同的数据集合,采用不同的聚类方法,可能得到不同的聚类结果。即便是采用同一种聚类方法,若初始参数(如聚类数、聚类中心等)选择不同也可能会得到不同的结果。例如,采用同一种 k 均值聚类算法对同一个 Wine 测试数据集(来自 UCI 机器学习数据库)进行聚类,当预设聚类类别数分别为 1~8 时,则得到的聚类正确率是不同的,如图 6.7 所示。




图 6.7 不同的聚类数初值导致 k 均值的聚类正确率不同

此外,对于基于目标函数的聚类算法,迭代优化易收敛于局部极值,难以获得全局最优解。以 k 均值为例,常采用梯度下降法实现迭代。由于梯度法的搜索方向是沿着能量减小的方向进行,因此易陷入局部极值。例如,对于图 6.8 所示的由 12 个对象组成的集合,显然不管采用什么聚类方法,其结果均应为 3 类,结论应该是一致的。然而,理论分析和仿真实验均表明,使用 k 均值求解这一简单问题时,经常会出现错解或无解的情况。若按横坐标从小到大将对象依次编号为 1~12,当 3 个初始中心分别选取 2、3 和 6,或 6、10 和 11 或 1、4 和 8 时,算法均得出错误的结论;当 3 个初始中心选取 1、4 和 10 时,算法得不到任何解。为了克服上述问题,近年来提出了多种算法以提高目标函数的优化效率。1999 年 Krishma 根据遗传算法的原理以 k 均值算子代替遗传算法中的交叉算子,提出了一种混合遗传算法;2000 年 Mali 采用聚类中心的浮点编码方法,并设计了浮点数交叉和变异算子,从而提高聚类算法的搜索效率。但是,仿真实验表明,当聚类数目、对象个数和维度较大时,这两种基于遗传算法的聚类经常会出现早熟现象。聚类规模越大,早熟现象越容易发生,而且




图 6.8 k 均值算法失效的实例



由于进化算法在进化过程中可能产生退化现象,从而导致迭代次数过多以及聚类准确率不高,并且可能出现进化后期的波动现象;2003年行小帅等提出了基于免疫规划的k均值聚类算法,其主要思想是在合理提取免疫疫苗的基础上,通过接种疫苗和选择操作分别提高个体的适应度并防止群体的退化,从而有效地避免局部极值,具有良好的全局寻优性。

如何评价不同聚类算法的性能呢?评价聚类算法的一般标准包括:

#### 1. 可伸缩性

即算法中模式数增大的情况。有些算法在模式数量小的情况下,算法性能很好,但是模式数量增大后,算法性能下降。如k中心点算法,它对小的数据集非常有效,但对大的数据集不具有良好的可伸缩性。

#### 2. 高维性

即算法中模式属性个数增加的情况。有些算法只擅长处理低维数据,高维空间的聚类是一个挑战,特别是非常稀疏和偏斜的数据。

#### 3. 发现任意形状的聚类

一个簇可能是任意形状的,但一般的聚类算法是基于欧氏距离和曼哈顿距离实现聚类,更趋于发现球状簇,在这方面基于密度的方法较好。

#### 4. 处理噪声的能力

噪声可能是数据本身不完整,也可能是孤立点。有些算法不善于处理孤立点数据,由此还专门出现了发现孤立点的算法。

#### 5. 用于决定输入参数的领域知识最小化和输入顺序敏感性

一方面要求降低算法对输入参数的敏感程度,另一方面要求输入顺序对算法结果的影响小。如k均值算法,需要预先给出簇的数目,这一参数非常影响聚类结果,这常常是高效率算法的弱点。

#### 6. 可解释性和可用性

聚类结果需要表现为一定的知识,即要求聚类结果可解释、易理解。这与可视化密切相关,同时也与实际应用有关。如SOM算法用于文本聚类可以产生知识地图,具有良好的可视化功能。

1965年,Zadeh首次给出聚类有效性的度量——分离度(degree of separation)。但是,后来发现它对模糊聚类有效性的判断并不十分有用;1974年Bezdek提出划分系数(partition coefficient),这是第一个有用的度量聚类有效性的泛函,旨在度量各聚类之间的“重叠”程度。

**定义 6.3** 设 $U \in M_c$ 为集合 $X$ 的模糊 $c$ 划分, $|X|=n, 2 \leq c < n$ ,则 $U$ 的划分系数是:

$$F(U;c) = \frac{\sum_{k=1}^n \sum_{i=1}^c (u_{ik})^2}{n} \quad (6.57)$$

其中, $n$ 为数据集的对象个数, $c$ 为模糊聚类个数, $u_{ik}$ 为数据对象 $k$ 属于类 $i$ 的模糊隶属度。若所有的 $u_{ik}$ 接近0或1,则熵小,所给出的聚类效果较好;若 $u_{ik}$ 接近0.5,则聚类的模糊程度高,则熵大,聚类效果较差。最佳有效划分是 $\max_c \{ \max_{a_c} \{ F(U;c) \} \}$ 。其主要缺点是具有单调下降趋势以及与数据集本身的特征缺少直接关联。

类似地,Shannon提出了划分熵(classification entropy)。

**定义 6.4** 设  $U \in M_{fc}$  为集合  $X$  的模糊  $c$  划分,  $|X| = n, 1 \leq c < n$ , 则  $U$  的划分熵是:

$$H(U; c) = \frac{- \sum_{j=1}^n \sum_{i=1}^c (\mu_{ij})^2 \log_a(u_{ij})}{n} \quad (6.58)$$

其中  $a \in (1, \infty)$ , 且只要  $u_{ij} = 0$  则  $u_{ij} \log_a(u_{ij}) = 0$ 。最佳有效划分是  $\min_c \{ \min_{a_c} \{ H(U; c) \} \}$ 。划分系数与划分熵两者之间的关系可表示为:

$$0 \leq 1 - F(U; c) \leq H(U; c) / \log_a(e) \quad (6.59)$$

其中,  $a \in (1, \infty)$ , 且  $e = 2.718 \dots$ 。

为了克服上述两种有效性函数的不足, Windham 提出比例指数 (proportion exponent)。

**定义 6.5** 设  $U \in (M_{fc} - M_w)$  为集合  $X$  的模糊  $c$  划分,  $|X| = n, 2 \leq c < n$ , 对于  $U$  的  $k$  列 ( $1 \leq k \leq n$ ), 使

$$u_k = \max_{1 \leq i \leq c} \{ u_{ik} \} = \bigvee_{i=1}^c u_{ik} \quad (6.60)$$

$$[u_k^{-1}] = \text{greatest int eger} \leq \left( \frac{1}{u_k} \right) \quad (6.61)$$

则  $U$  的比例指数是:

$$P(U; c) = -\log_e \left\{ \prod_{k=1}^n \left[ \sum_{j=1}^k (-1)^{j+1} \binom{c}{j}^{[u_k^{-1}]} \left( 1 - j \cdot \bigvee_{i=1}^c u_{ik} \right)^{c-1} \right] \right\} \quad (6.62)$$

最佳有效划分是  $\max_{2 \leq c \leq n} \{ \max_{a_c} \{ P(U; c) \} \}$ 。

后来, Gunderson 提出分离系数 (separation coefficient), 考虑了数据集的几何特征, 但无法直接应用于模糊聚类, 必须首先将模糊聚类转换为硬聚类。

直到 1989 年 Xie 和 Beni 提出了 Xie-Beni 方法, 才使聚类有效性问题得以进一步发展。

设数据集  $X = \{X_j, j = 1, 2, \dots, n\}$  具有  $c$  个模糊划分,  $V_i (i = 1, 2, \dots, c)$  为各聚类中心,  $\mu_{ij} (i = 1, 2, \dots, c; j = 1, 2, \dots, n)$  为数据对象  $j$  属于类  $i$  的模糊隶属度。

**定义 6.6**  $d_{ij} = \mu_{ij} \|X_j - V_i\|$  为  $X_j$  与类  $i$  的模糊偏移。

由定义 6.6 可知,  $\|\cdot\|$  为通用的欧氏范式,  $d_{ij}$  为  $X_j$  与  $V_i$  之间的欧氏距离。

**定义 6.7**  $n_i = \sum_x j \mu_{ij}$  为类  $i$  的模糊势。

由定义 6.7 可知  $n_i = \sum_x i n_i = n$ , 在硬划分的极端情况下  $n_i$  具有确定的数值, 即类  $i$  中的矢量个数。

**定义 6.8**  $\sigma_i = \sum_x j (d_{ij})^2 = (d_{i1})^2 + (d_{i2})^2 + \dots + (d_{in})^2$  为类  $i$  的偏差, 即对于任意的类  $i$  所有数据对象偏移的平方和,  $\sigma = \sum_x i \sigma_i = \sum_x i \sum_x j (d_{ij})^2$  为所有聚类的总偏差。

由定义 6.8 可知, 它们并没有进行标准化处理, 并且与所选用的坐标系有关。  $\sigma$  值越小, 则聚类效果越好。

**定义 6.9**  $\pi = \frac{\sigma}{n}$  为数据集模糊  $c$  划分的紧致度, 即总偏差与数据集大小的比率。

$\pi$  值表示每一聚类的紧致程度, 聚类越紧密, 则  $\pi$  值越小, 表明数据集本身的分布特点,



与对象数量无关。 $\pi$  值小,则表明聚类效果较好。Gath 和 Geva 给出了一种模糊超体积的有效性度量(加权总偏差),可以判断椭圆体聚类以及重叠的聚类。

**定义 6.10**  $\pi_i = \frac{\sigma_i}{n_i}$  为类  $i$  的紧致度。

因为类  $i$  中的矢量个数为  $n_i$ ,所以  $\sigma_i/n_i$  为类  $i$  的平均偏差。此外,模糊  $c$  划分的紧致度还可以定义为  $\pi = (\sum_i \pi_i)/c$  或  $\pi = \max \pi_i$ 。

**定义 6.11**  $s = (d_{\min})^2$  为模糊  $c$  划分的分离度,其中  $d_{\min} = \min_{i,j} \|V_i - V_j\|$  为各聚类中心之间的最短距离。

$s$  值越大,则表明所有的聚类都是分离的。

**定义 6.12**  $S = \frac{\pi}{s}$  为基于紧致度和分离度的有效性函数,即:

$$S = \frac{\sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^2 \|V_i - X_j\|^2}{n \min_{i,j} \|V_i - V_j\|^2} \quad (6.63)$$

由定义 6.12 可知, $S$  的定义与计算  $\mu_{ij}$  所采用的方法无关。 $S$  越小,则表明所有聚类紧密且相互独立。随着  $c$  的增加而接近  $n$  时, $S$  将单调递减。为此,可引入专门的惩罚函数以消除递减趋势。即使不采用惩罚函数,有效性函数  $S$  仍然是一种行之有效的方法。

由此给出一种采用  $S$  作为有效性函数的启发策略。对于任何一种模糊聚类算法,发现数据集  $X$  的一个或多个最佳  $c$  划分( $c=2,3,\dots,n-1$ )可表示为:

$$\min_{2 \leq c \leq n-1} \{ \min_{\Omega_c} S \} \quad (6.64)$$

其中, $\Omega_c$  为对于每个  $c$  的最适合的候选数据样本。

有效性函数  $S$  和划分系数  $F$  都是判断模糊聚类有效性的标准,均可以直接使用,但两者也存在不同之处。首先, $F$  与任意模糊子集之间的平均重叠程度成反比,而  $S$  与平均紧致度和分离度成正比;其次, $F$  缺少与数据集本身某些特征的直接关联,而  $S$  则与数据集的几何特征、距离的度量方法及聚类中心的位置等存在着直接关系。

后来又给出了一个新的划分系数  $P(u,c)$ ,其定义的聚类有效性函数  $FP(u,c)$  为

$$FP(u,c) = P(u,c) = \frac{1}{c \sum_{i=1}^c \left( \sum_{k=1}^n u_{ik}^2 / \sum_{k=1}^n u_{ik} \right)} \quad (6.65)$$

基于聚类本身的物理意义给出了一个模糊聚类有效性函数  $\eta(X,c)$ 。

**定义 6.13** 给定  $X = \{x^p, p=1,2,\dots,N\} \in R^n$ ,样本  $x^p = (x_{p1}, x_{p2}, \dots, x_{pn})$ 。设聚类个数为  $c (2 \leq c < N)$ ,聚类中心为  $u = (v_1, v_2, \dots, v_c)^T \in R^n$ ,则称集合  $M_c$  是  $X$  的一个模糊  $c$  划分。

$$M_c = \left\{ U \in V_{cN} \mid \mu_{pj} \in [0,1], \forall j,p; \sum_{j=1}^c \mu_{pj} = 1, \forall p; 0 < \sum_{p=1}^N \mu_{pj} < N, \forall j \right\} \quad (6.66)$$

在式(6.66)中, $\mu_{pj} = \mu_j(x^p)$  表示  $x^p$  属于第  $j$  类的隶属度, $U = \{u_1, u_2, \dots, u_c\}^T$ ,  $u_j = (u_{j1}, u_{j2}, \dots, u_{jN})$  是样本  $X$  的第  $j$  个聚类集合, $V_{cN}$  是  $c \times N$  阶实矩阵的集合。

根据定义 6.13, 模糊划分的紧致度定义为 FCM 划分的平均方差, 即:

$$\Psi(\chi, c) = \frac{1}{N} \sum_{j=1}^c \sum_{p=1}^N \mu_{jp}^2 (x^p - v_j)^T A (x^p - v_j) \quad (6.67)$$

其中,  $A$  为  $n \times n$  正定加权矩阵, 可将欧拉空间扩展到其他空间。

根据定义 6.13, 模糊划分的分离度定义为不同聚类中心之间的平均距离, 即:

$$\Phi(v) = \frac{1}{|R|} \sum_{j=1}^{c-1} \sum_{h=j+1}^c (v_i - v_h)^T A (v_i - v_h) \quad (6.68)$$

其中,  $|R|$  为集合  $R = \{(v_i, v_h) | d(v_i, v_h) = \|v_i - v_h\|, i \neq h, 1 \leq i, h \leq c\}$  的势。

模糊聚类有效性函数  $\eta(\chi, c)$  定义为:

$$\eta(\chi, c) = \frac{\Psi(\chi, c)}{\Phi(v)} \quad (6.69)$$

有效性函数  $\eta(\chi, c)$  被定义为紧致度和分离度之比。显然, 模糊划分形成的同一聚类中的对象靠得越紧, 不同聚类中心的距离越远, 则模糊聚类结果的合理程度越好。模糊聚类的合理划分即尽量使  $\eta(\chi, c)$  越小越好, 这样则代表了一个最有效的划分, 并由此确定聚类数  $c$ 。

但是, 随着  $c$  增加而接近  $N$  时, 聚类有效性函数  $\eta(\chi, c)$  具有单调性。

聚类有效性是聚类分析的一个瓶颈, 对于聚类的成功应用将产生十分深远的影响。



## 第7章 分类和预测

分类(classification)是数据挖掘的主要功能之一,通过分析类别已知的训练数据集,获得描述并区分类别或概念的模型,使用该模型预测并标记未知对象所属的类别。

分类的目的是分析输入数据,通过训练集中数据表现出来的特性,获得每个类别准确的描述或模型,这种描述常常用谓词表示,使用类别描述对未知对象进行分类。尽管这些测试数据的类别是未知的,仍可预测这些新数据所属的类。注意是预测,而不能肯定。

分类的评价遵循以下标准:

- 预测准确率 指模型能够正确预测未知对象类别的能力。
- 速度 指构造和使用模型时的计算效率。
- 鲁棒性 指在数据带有噪声或数据有缺失的情况下,模型仍能进行正确预测的能力。
- 可扩展性 指对处理大量数据并构造有效模型的能力。
- 易理解性 指所获模型提供的可理解程度。

分类是一种有监督的学习,其目的是根据训练数据集找出能准确描述并区分类别或概念的模型,以便依据实体的属性值及其他约束条件将其划分到某一类别中。目前,主要的分类算法包括决策树、贝叶斯、神经网络、遗传算法、粗糙集和实例推理等。

(1) 决策树是经典的分类算法,采用自顶向下递归、各个击破的方式构造决策树。树的每一个结点使用信息增益选择属性,从生成的决策树中可提取分类规则。

(2) KNN(K-Nearest Neighbor, K 最近邻)是由 Cover 和 Hart 于 1968 年提出,算法主要思路非常简单直观,即如果一个样本在特征空间中的  $k$  个最相似(特征空间中最邻近)的样本中的大多数属于某个类别,则该样本也属于这一类别,即分类时只依据最邻近的一个或几个样本所属的类别决定待分类样本的类别。虽然, KNN 在原理上也依赖于极限定理,但在分类决策时,只与极少量的相邻样本有关。因此,该方法可以较好地避免样本不平衡的问题。另外,由于 KNN 主要依靠有限的邻近样本,而不是靠判别类域的方法确定所属类别,因此对于类域交叉或重叠较多的待分类样本集而言, KNN 更为适用。KNN 的不足之处是计算量较大,因为对每一个待分类的样本都要计算其到全体已知样本的距离,才能求得其  $k$  个最近邻。目前常用的解决方法是事先对已知样本进行剪辑,去除对分类作用不大的样本。此外, Reverse KNN 能降低 KNN 的计算复杂度,提高分类效率。KNN 比较适用于样本数量比较大的类域的分类,而那些样本数量较小的类域采用这种算法则容易产生误差。

(3) SVM(Support Vector Machine, 支持向量机)由 Vapnik 等人于 1995 年提出,具有相对良好的性能。该方法是建立在统计理论上的机器学习方法。通过学习 SVM 可以自动寻找出那些对分类有较好区分能力的支持向量,由此构造的分类器可以最大化类与类的间隔,因而具有较好的适应能力和较高的分准率。该方法是由各类域边界样本的类别决定最后的分类结果。该算法旨在寻找一个超平面,该超平面可以将训练集中的样本分离,且与类



域边界沿垂直于该超平面方向的距离最大,故 SVM 亦被称为最大边(maximum margin)算法。SVM 对小样本量的分类效果较好。

(4) 贝叶斯是一种已知先验概率与类条件概率的分类方法,待分类样本的分类结果取决于各类域中样本的全体。设训练样本集分为  $M$  类,记为  $C = \{c_1, c_2, \dots, c_M\}$ ,每类的先验概率为  $P(c_i)$ ,其中  $i = 1, 2, \dots, M$ 。当样本集非常大时,可以认为  $P(c_i) = c_i$  类的样本数/总样本数。对于一个待分类样本  $X$ ,其归于  $c_j$  类的条件概率是  $P(X/c_i)$ ,根据贝叶斯定理可得到  $c_j$  类的后验概率  $P(c_j/X)$  为:

$$P(c_i/X) = P(X/c_i)P(c_i)/P(X) \quad (7.1)$$

$$\text{若 } P(c_i/X) = \text{Max}_j P(c_j/X), i = 1, 2, \dots, M, j = 1, 2, \dots, M, \text{ 则 } X \in c_i \quad (7.2)$$

式(7.2)是最大后验概率判决准则,将式(7.1)代入式(7.2),则若  $P(x/c_i)P(c_i) = \text{Max}_j [P(x/c_j)P(c_j)], i = 1, 2, \dots, M, j = 1, 2, \dots, M$ , 则  $X \in c_i$ ,即常用的贝叶斯分类判决准则。经过长期的研究,理论上贝叶斯论证较充分,应用非常广泛。

贝叶斯分类的不足之处是实际情况下类别总体的概率分布和各类样本的概率分布函数(或密度函数)常常是未知的,若要获得则要求样本量足够大。另外,贝叶斯分类要求各条件概率相互独立,实际一般很难满足,因此往往在效果上难以达到理论最大值。

分类和回归都可以实现预测,分类预测的是二元值或离散的类别,而回归预测的是连续或有序值。分类预测和回归预测流程基本相同,即数据准备时,从所有数据集中提取部分数据,作为训练集。同时将剩余的数据作为测试集,利用分类算法对训练集进行分析,得到分类模型。利用测试集对训练后的分类模型进行评估,判断分类模型是否准确。最后,使用该模型对未知样本进行预测。

传统的预测方法包括趋势外推法、时间序列法和回归分析法等。

(1) **趋势外推法**通常用描散点图的方法定性确定变化趋势,再按照该变化趋势对未来情况做出预测,特点是不对其中的随机成分作统计处理。

(2) **时间序列法**将因变量(预测目标)和自变量(影响预测目标的因素)均看成随机变量。实际问题中,多数预测目标的观测值构成的序列表现为(广义)平稳的随机序列或可以转化为平稳的随机序列。虽然在某一给定时刻预测目标的观测值是随机的,但从整个观测序列看,却呈现出某种随机过程(如平稳随机过程)的特性。随机时间序列方法正是依据这一规律建立和估计产生实际序列的随机过程模型,然后利用这些模型进行预测。

(3) **回归分析法**假定目标同一个或多个独立变量存在关联,寻找关联关系的模型。不同于时间序列法的是模型的因变量是随机变量,而自变量是可控变量。回归可分为线性和非线性,目前多用多元线性回归模型。

## 7.1 神经网络

神经网络(Neural Network, NN)是由大量神经元(又称为处理单元)广泛互连组成的网络,是在现代神经生物学基础上模拟生物过程以反映人脑某些特性的计算结构。它不是人脑神经系统的真实刻画,而只是某种抽象、简化和模拟。信息的处理是由神经元之间的相互



作用实现,知识与信息的存储表现为神经元互连间分布式的物理联系,学习和识别决定于各神经元连接权值的动态演化过程。神经网络是一个具有高度非线性的超大规模连续的时间动力系统。

神经元是神经网络的基本单元,一般是多输入/单输出的非线性器件,其结构模型和 I/O 特性分别如图 7.1 和图 7.2 所示。




图 7.1 神经元的结构模型




图 7.2 神经元的 I/O 特性

图 7.1 中,  $u_i$  为神经元的内部状态,  $\theta_i$  为阈值,  $x_i$  为输入,  $y_i$  为输出,  $w_{ji}$  是神经元  $u_i$  到  $u_j$  的连接权值,  $s_i$  为外部输入(某些情况下,它可以控制神经元  $u_i$  使其保持在某一状态),神经网络模型可描述为:

$$\begin{aligned}\sigma_i &= \sum_j w_{ji} x_j + s_i - \theta_i \\ u_i &= f(\sigma_i) \\ y_i &= g(u_i) = h(\sigma_i) \quad h = g \cdot f\end{aligned}\quad (7.3)$$

常用的神经元非线性特性描述如下:

(1) 域值型,函数  $f$  为阶跃函数,如图 7.2(a)所示。

$$f(x_i) = \begin{cases} 1, & x_i > 0 \\ 0, & x_i \leq 0 \end{cases} \quad (7.4)$$

(2) 分段线性型,如图 7.2(b)所示。

(3) S 型,一般没有内部状态并连续取值,其 I/O 特性常用对数或正切等 S 型曲线表示,例如:

$$x_i = \frac{1}{1 + \exp(-x_i)} \quad (7.5)$$

或

$$x_i = \frac{1}{2} [1 + \tan(\sigma_i/x_i)] \quad (7.6)$$

这类曲线反映了神经元的饱和特性,如图 7.2(c)所示。

目前,已有近四十种神经网络模型,具有代表性的是 BP(Back Propagation,反向传播)神经网络、自适应共振理论(Adaptive Resonance Theory,ART)、Hopfield 神经网络、神经认知机、感知器和自组织映射等。其中,BP 神经网络的应用最为广泛,下面将介绍 BP 神经网络分类器。

BP 神经网络由输入层、隐层和输出层组成,如图 7.3 所示。

BP 神经网络分类器是将训练样本的各属性值作为输入,实际类别作为输出。对训练后的 BP 网络,通过剪枝、神经元或活跃值的聚类处理,导出输入层和输出层的关联规则,根据这些规则实现分类。BP 神经网络中,反向传播学习通过一个使目标函数最小化的过程完成




图 7.3 BP 神经网络的结构

输入到输出的映射, 目标函数定义为输出层神经元的期望输出与实际输出的误差平方和, 即:

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_j (t_{pj} - O_{pj})^2 \quad (7.7)$$

其中,  $t_{pj}$  是在输入第  $P$  个样本时输出层单元  $j$  实际输出  $O_{pj}$  的期望输出。目标函数  $E$  曲面上梯度下降由下面的公式计算得到:

$$\begin{aligned} \frac{\partial E}{\partial W_{ji}} &= \sum_p \left( -\frac{\partial E_p}{\partial W_{ji}} \right) = \sum_p \delta_{ij} g O_{ij} \\ -\frac{\partial E}{\partial \theta_j} &= \sum_p \left( -\frac{\partial E_p}{\partial \theta_j} \right) = \sum_p \delta_{ij} \end{aligned} \quad (7.8)$$

对于输出层单元  $j$ , 一般化误差  $\delta_{pj}$  表示为:

$$\delta_{pj} = (t_{pj} - O_{pj}) g(1 - O_{pj}) g O_{pj} \quad (7.9)$$

对于隐含层,  $\delta_{ij}$  表示为:

$$\delta_{ij} = O_{ij} g(1 - O_{ij}) g \sum_k \delta_{ik} W_{ik} \quad (7.10)$$

据此可以调整各连接权重和阈值。

分类前需要确定 BP 神经网络的拓扑结构, 即确定隐层的神经元个数及各神经元初始的权值和阈值。理论上, 隐层的神经元数量越多, 逼近越精确。实际中, 隐层神经元数量不宜过多; 否则会极大地增加训练时间, 并造成神经网络容错能力下降。同时, 为了加速学习和训练, 需将训练样本各属性值归一化到区间  $[0, 1]$ 。对离散属性可重新编码, 使各阈值对应一个输入神经元, 例如输入样本  $P$  为  $(p_0, p_1, \dots, p_n)$ , 则可设置  $I_0, I_1, \dots, I_n$  共  $n+1$  个输入。输出也需进行归一化, 主要针对实际类别与输出神经元的对应关系。当只有两个类别时, 可用一个输出神经元表示 (0 表示一个类别, 1 表示另一个类别); 若实际输出多于两个



类别,则可以每个类别分别对应一个输出神经元。

BP神经网络存在的主要问题包括:

(1) 收敛速度 BP算法最大的弱点是其训练很难收敛,其训练速度是非常慢的,尤其是当网络训练达到一定的程度后。

(2) 局部极小值 BP算法采用梯度下降法,对一个复杂网络而言,其误差曲面是一个高维空间的曲面,其中分布着许多局部极小值,一旦陷入局部极小值则很难逃离。

(3) 网络瘫痪 在学习训练中,权值可能变得很大,这会使神经元输入变得更大,导致其激励函数的一阶导数在此点上的值很小。此时的训练步长会变得非常小,最终造成网络停止收敛,即出现所谓的网络瘫痪。

BP神经网络分类算法的类C语言描述如下:

输入: 训练样本集合,学习率  $\eta$ , 多层前馈神经网络

输出: 一个用于对样本分类的BP神经网络

初始化BP神经网络的权值  $w_{ij}$  和阈值  $\theta_j$ ;

```
while 不满足训练终止条件{
    for samples 中的各训练样本  $x$  {      //正向传播输入
        for 隐层或输出层的各神经元  $j$  {
             $I_j = \sum_i w_{ij} * O_i + \theta_j$ ;      //相对于前一层  $i$ , 计算神经元  $j$  的输入  $I_j$ 
             $O_j = 1/(1 + e^{-I_j})$ ;          //使用对数型的单极性 Sigmoid 函数将各神经元  $j$  的输出映射到区间[0,1]

            for 输出层的各神经元  $j$           //反向传播误差
                 $ERR_j = O_j * (1 - O_j) * (T_j - O_j)$ ; //根据训练样本的已知类标号真实输出  $T_j$ , 计算神经元  $j$  的误差  $ERR_j$ 

            for 从最后 1 个到第 1 个隐层的各神经元  $j$ 
                 $ERR_j = O_j * (1 - O_j) * \sum_k (ERR_k * w_{jk})$ ; //根据下一较高层中连接到  $j$  的所有神经元的误差加权值来计算隐层神经元  $j$  的误差  $ERR_j$ 

            for BP 神经网络中的各权值  $w_{ij}$     //更新权值
                {
                     $\Delta w_{ij} = \eta * ERR_j * O_i$       //实际应用时,  $\eta$  一般经验性地设置为训练样本集迭代次数 //的倒数
                     $w_{ij} = w_{ij} + \Delta w_{ij}$ 
                }

            for BP 神经网络中的各阈值  $\theta_j$     //更新阈值
                {
                     $\Delta \theta_j = \eta * ERR_j$ 
                     $\theta_j = \theta_j + \Delta \theta_j$ 
                }
        }
    }
}
```

BP神经网络分类算法的流程如图7.4所示。其学习过程分为正向传播输入和反向传播误差。样本从输入层经隐层再到输出层,逐层处理时各层神经元状态只对下一层神经元的状态产生影响。在输出层,实际输出和期望输出不一致时,进入反向传播过程,即将误差反向传播,并通过更新权值和阈值调整,使误差趋向最小。

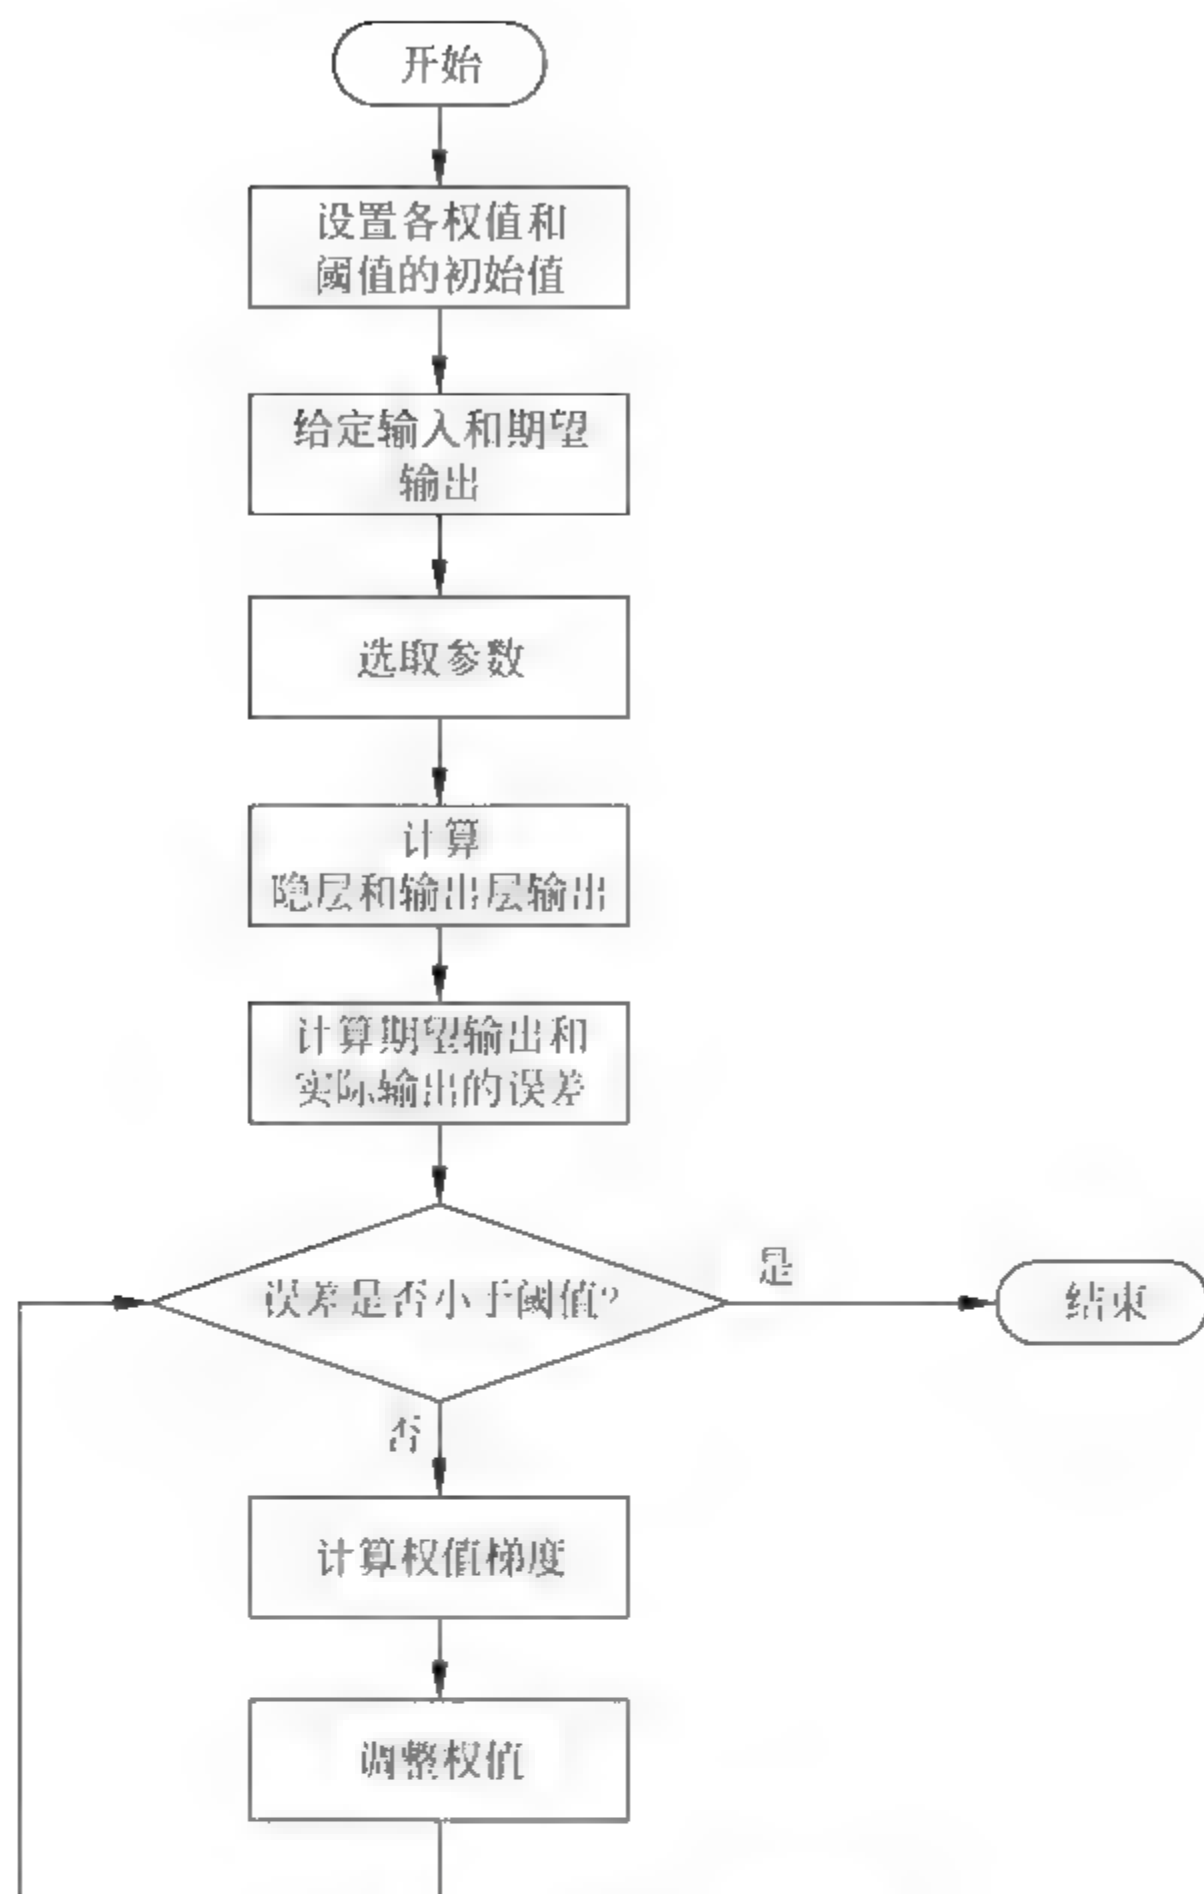


图 7.4 BP 算法流程图

## 7.2 决策树

决策树(decision tree)是分类预测的主要方法,采用基于实例的归纳学习算法,旨在从一组无次序、无规则的实例中推理出决策树形式的分类规则,采用自顶向下的递归方式,在决策树的内部结点进行属性值的比较并根据不同属性判断从该结点向下的分支,在决策树的叶结点得到结论,所以从根到叶结点对应一条合取规则,整棵树对应一组析取规则。

决策树分类是利用属性值对各子集逐级划分,直到一个结点仅含有同一类样本为止。决策树最早起源于 Hunt 等人提出的概念学习系统(Concept Learning System,CLS),然后发展到 Quinlan 的 ID3 算法,最后演化为能处理连续值属性的 C4.5 算法。

### 1. 主要算法

下面介绍三种主要的决策树算法。

#### 1) CLS

以一棵空决策树开始,通过增加结点逐步求精,直到产生一棵能正确分类训练样本的决策树为止,是一个循环递归过程。假设  $T$  为已知的训练集,则:



(1) 如果  $T$  的所有样本均为正例,则生成一个 YES 结点并终止;如果  $T$  的所有样本均为反例,则生成一个 NO 结点并终止;否则,根据某种启发式策略选择一个属性  $A$ ,设  $A$  取值为  $v_1, v_2, \dots, v_r$ ,并生成新结点。

(2) 将  $T$  根据其属性  $A$  的取值进行划分,生成  $r$  个子集,记为  $T_1, T_2, \dots, T_r$ 。

(3) 递归地应用该算法到每个子集  $T_i$ 。

CLS 中,分类属性的选择决定了算法的效率与所生成决策树的繁简程度和预测效果。属性选择是决策树算法的关键。

CLS 可以产生所有可能的决策树,正确分类训练实例,并能选择最简单的决策树。但是属性选择范围在实际应用中往往受到问题大小的限制。

## 2) ID3

Quinlan 提出著名的 ID3 学习算法,是对 CLS 的改进,通过选择窗口形成决策树,利用信息论中的互信息(mutual information)或信息增益(information gain)选择具有最大信息量的属性,建立决策树的一个结点,再根据该属性的不同取值建立树的分支,在每个分支中重复建立树的下层结点和分支,效果非常理想。其优点是描述简单,分类速度快,特别适合大规模数据集。但算法引入信息论中的互信息作为单一属性能力的度量,试图减少树的平均深度,忽略了叶子数目的研究,其启发式函数并不是最优的,存在的主要问题是:

(1) 互信息的计算依赖于取值数目较多的属性,而取值较多的属性不一定最优。

(2) ID3 是非递增式学习算法。

(3) 抗噪能力差,训练集中正例和反例较难控制。改进算法包括 C4.5 以及 CART(引进可调错误率-adjusted error rate 概念)等。

下面给出 ID3 算法的一个实例。例如根据天气状况预测某天是否适合打高尔夫球,适合的属于正例记为  $p$ ,不适合的属于反例记为  $n$ 。天气由四种属性描述,即 Outlook 取值分别为 sunny、overcast 和 rain; Temperature 取值分别为 cool、mild 和 hot; Humidity 取值为 normal 和 high; Windy 取值为 false 和 true。训练集中共有 14 个样本,如表 7.1 所示。

表 7.1 打高尔夫球天气形势的训练集

序号	Outlook	Temperature	Humidity	Windy	Class
1	sunny	hot	high	false	N
2	sunny	hot	high	true	N
3	overcast	hot	high	false	P
4	rain	wind	high	false	P
5	rain	cool	normal	false	P
6	rain	cool	normal	true	N
7	overcast	cool	normal	true	P
8	sunny	mild	high	false	N
9	sunny	cool	normal	false	P
10	rain	mild	normal	false	P
11	sunny	mild	normal	true	P
12	overcast	mild	high	true	P
13	overcast	hot	normal	false	P
14	rain	mild	high	true	N

由表 7.1 可知  $p=9, n=5$ , 则

$$I(p, n) = -\frac{9}{14} \log_2 \frac{9}{14} - \frac{5}{14} \log_2 \frac{5}{14} = 0.940$$

$$\begin{aligned} E(\text{outlook}) &= \frac{5}{14} I(p_1, n_1) + \frac{4}{14} I(p_2, n_2) + \frac{5}{14} I(p_3, n_3) \\ &= \frac{5}{14} I(2, 3) + \frac{4}{14} I(4, 0) + \frac{5}{14} I(3, 2) \\ &= \frac{5}{14} \times 0.971 + \frac{4}{14} \times 0 + \frac{5}{14} \times 0.971 \\ &= 0.694 \end{aligned}$$

$$\text{Gain}(\text{Outlook}) = I(p, n) - E(\text{outlook}) = 0.940 - 0.694 = 0.246$$

类似地, 可得:

$$\text{Gain}(\text{Temperature}) = 0.029$$

$$\text{Gain}(\text{Humidity}) = 0.151$$

$$\text{Gain}(\text{Windy}) = 0.048$$

显然 Outlook 的信息增益最大, 因此 Outlook 被选为根结点并向下扩展, 以此类推, 得到相应的 ID3 决策树, 如图 7.5 所示。




图 7.5 打高尔夫球的 ID3 决策树

### 3) C4.5

ID3 有很多改进算法, 其中 Quinlan 在 1994 年开发的 C4.5 流行最广。C4.5 的改进主要体现在两个方面:

- (1) 解决连续取值的学习问题。
- (2) 提供学习结果决策树到等价规则集的转换功能。

C4.5 属于一种归纳学习(inductive learning)算法, 旨在从大量的训练样本中归纳抽取一般的判定规则和模式, 是机器学习(machine learning)领域最成熟的分支之一。根据有无监督指导, 归纳学习又分为有监督学习(supervised learning)和无监督学习(unsupervised learning)。有监督学习可分为覆盖算法(covering algorithm)和分治算法(divide and conquer algorithm), 前者归纳生成规则, 后者归纳生成决策树。C4.5 属于有监督的学习算法。

### 4) SLIQ 算法

构造决策树时, SLIQ 采用预排序和广度优先策略。在一般决策树中, 使用信息增益评价结点分裂的质量。SLIQ 使用 Gini 指标(Gini index)代替信息增益, 对有  $n$  个分类的数据集  $S$ ,  $\text{gini}(S)$  定义为:



$$\text{gini}(S) = 1 - \sum p_j * p_j \quad (7.11)$$

其中,  $p_j$  是  $S$  中第  $j$  类数据的频率。gini 越小, 信息增益越大。

区别于一般的决策树, SLIQ 采用二分查找树结构。对每个结点都需要先计算最佳分裂方案, 然后执行分裂。对于连续值属性 (numerical attribute) 分裂可以先对属性值排序, 假设排序后的结果为  $V_1, V_2, \dots, V_n$ , 因为分裂只发生在两个结点之间, 所以有  $n-1$  种可能性。从小到大依次取不同的分裂点, 通常取中点  $(V_i + V_{i+1})/2$  作为分裂点, 使信息增益最大 (即 gini 最小) 的即最佳分裂。因为每个结点都需要排序, 所以代价很大, 降低排序成本是一个重要的问题, SLIQ 对此有很好的解决方案。对于离散值属性 (categorical attribute), 设  $S(A)$  为  $A$  的所有可能的值, 属性分裂将遍取  $S$  的所有子集  $S'$ , 获得分裂成  $S'$  和  $S-S'$  时的 gini 指标。当 gini 最小时, 即最佳分裂。显然, 这是一个遍历集合  $S$  所有子集的过程, 共需要计算 2 次, 代价很大。SLIQ 对此也有一定程度的优化。

SLIQ 的处理能力比 ID3 和 C4.5 大得多, 因此在一定程度上具有良好的可扩展性, 但仍存在不足之处, 主要体现在:

(1) 需要将类别列表存放于内存, 而类别列表的长度与训练集的长度相同, 这在一定程度上限制了处理数据集的大小。

(2) 预排序的复杂度本身并不是与样本数量成线性关系, 因此 SLIQ 不可能达到随样本数增长的线性可扩展性。

## 2. 算法描述

ID3 算法的基本思路是首先在数据集中采用信息增益作为属性选择的标准, 找出最有影响力的属性, 将数据集分成多个子集, 每个子集又选择最具影响力的属性进行划分, 一直进行到所有子集仅包含同一类型的样本为止, 最后得到一棵决策树。决策树的构造采用自上而下, 分而治之的递归方式。初始时, 根结点包含数据集中的所有样本。若一个结点包含的样本均为同一类别, 则该结点成为叶结点并标记为该类别; 否则, 采用信息增益的度量选择合适的分类属性, 将数据集划分为若干个子集。该属性称为相应结点的测试属性 (test attribute)。对测试属性的每个已知值都创建一个分支, 同时也包含一个被划分的子集。递归地对所获得的每个划分形成一棵决策子树。一旦一个属性出现在某个结点上, 则不能再出现在该结点之后所产生的子树结点上。当一个结点包含的所有样本均为同一类别或没有样本满足测试属性值, 则算法终止。

基于信息增益选择测试属性的方法, 使得对一个对象分类所需的期望测试数达到最小, 确保得到一棵简单的树。在该方法中选择具有最高信息增益的属性作为当前结点的测试属性, 该属性使得数据样本分类所需的信息量最小, 并反映划分的最小随机性或“不纯性”。属性信息增益的计算方法如下:

设数据集  $S$  有  $s$  个样本, 类别属性有  $m$  个不同的取值, 定义  $m$  个不同的类  $C_i, i \in \{1, 2, 3, \dots, m\}$ 。设  $s_i$  为类别  $C_i$  的样本个数, 则对一个数据集分类所需要的期望信息为:

$$I(s_{1j}, s_{2j}, \dots, s_{mj}) = - \sum_{i=1}^m p_{ij} \log_2(p_{ij}) \quad (7.12)$$

其中  $p_i$  是任意一个样本属于类别  $C_i$  的概率, 可以按  $s_i/S$  计算。因为采用二进制编码, 所以对数函数以 2 为底。

设属性  $A$  可取  $v$  个不同的值  $\{a_1, a_2, \dots, a_v\}$ 。可以用属性  $A$  将  $S$  划分为  $v$  个子集  $\{S_1,$



$S_2, \dots, S_v$ , 其中  $S_j$  包含  $S$  中属性  $A$  中取值  $a_j$  为 1 的样本。若属性  $A$  为测试属性, 设  $s_{ij}$  为子集  $S_j$  中属于  $C_i$  类别的样本数。则利用属性  $A$  划分当前集合所需要的期望信息计算如下:

$$E(A) = \sum_{j=1}^v \frac{s_{1j} + s_{2j} + \dots + s_{mj}}{S} I(s_{1j}, s_{2j}, \dots, s_{mj}) \quad (7.13)$$

其中,  $\frac{s_{1j} + s_{2j} + \dots + s_{mj}}{S}$  称为第  $j$  个子集的权值。  $E(A)$  值越小, 表示子集划分结果越好。而对于一个给定子集  $S_j$ , 其期望信息如式(7.12)所示, 其中  $p_{ij} = \frac{s_{ij}}{|S_j|}$  为子集  $S_j$  中任一  
个样本属于类别  $C_i$  的概率。

由此利用属性  $A$  对当前分支结点进行划分所获得的信息增益是:

$$\text{Gain}(A) = I(s_{1j}, s_{2j}, \dots, s_{mj}) - E(A) \quad (7.14)$$

$\text{Gain}(A)$  是根据属性  $A$  进行集合划分所获得的信息熵的减少量。

ID3 计算每个属性的信息增益, 从中选择信息增益最大的属性作为给定集合的测试属性并由此产生相应的分支结点, 所产生的结点被标记为相应的属性, 并根据这一属性的不同取值分别产生相应的决策树分支, 每个分支代表一个被划分的子集。

ID3 算法简单, 学习能力较强, 但仅对较小的数据集有效, 且对噪声比较敏感, 当数据集增大时, 决策树可能会改变。C4.5 继承了 ID3 的优点, 同时对 ID3 进行了改进, 例如能够完成对连续属性的离散化处理, 能够对不完整数据进行处理等。

决策树的生成分为两个步骤:

1) 数据从根结点开始递归的进行数据分片

下面以 C4.5 为例说明决策树生成算法。

Procedure C4.5BuildTree ( $S, A$ )

( $S$ : 训练样本集,  $A$ : 分类属性集合)

if 属性是连续的则进行离散化处理

if 所有样本属于同一分类, 返回标号为该分类的叶结点

else if 属性值为空, 返回标号为  $S$  最普遍分类的叶结点

else{

For 每一个属性  $A$

估计该结点在  $A$  上的信息增益选出最佳的属性  $A$ , 将  $S$  分裂为  $S_i$ , 长出分支

( $S_i$  为属性  $A_j$  的第  $i$  个值对应的样本集)

For each  $S_i$

if  $S_i$  为空 then 返回叶结点, 标记为  $S$  中最普遍的类

else C4.5BuildTree ( $S_i, A - A_j$ )

}

2) 通过修剪去掉一些可能是噪声或者异常的数据

决策树分类算法的输入是一组带有类别标记的训练样本, 输出是一棵二叉或多叉树。二叉树的内部结点(非叶子结点)一般表示为一个逻辑判断, 例如形如  $a_i \rightarrow v_i$  的逻辑判断, 其中  $a_i$  是属性,  $v_i$  是该属性的某一取值; 树的边是逻辑判断的分支结果。多叉树(如 ID3)的内部结点是属性, 边是该属性的所有取值, 有几个属性值, 就有几条边。树的叶结点均为类别标记。决策树的构造采用自上而下的递归方法。以多叉树为例, 构造过程是如果训练



样本集合的所有样本是相同类别的,则将之作为叶结点,结点标记为该类别。否则,根据某种策略选择一个属性,按照属性的各个取值,把集合划分为若干子集,使得每个子集的所有样本在该属性上具有同样的属性值。然后再依次递归处理各个子集。本质上是“分而治之”(divide and conquer)。二叉树同理,差别仅在于要选择一个好的逻辑判断。构造决策树的关键是如何选择恰当的逻辑判断或属性。对于同一组样本,可以有很多决策树能符合这组例子。研究表明,一般情况下,树越小则预测能力越强,应构造尽可能小的决策树。由于构造最小的树是 NP 问题,因此只能采用启发式策略选择逻辑判断或属性,如信息增益、信息增益比(gain ratio)、gini index 和正交法等,不同的度量效果不同,特别是对于多值的属性。

#### C4.5 算法使用信息增益作为启发策略构造决策树。

在实际中,用于分类模型学习训练的样本往往是不完美的,原因在于:

- 某些属性字段缺值(missing value)
- 缺少必需的数据而造成数据不完整
- 数据不准确含有噪声甚至是错误的

因此,需要克服噪声和决策树剪枝。

剪枝旨在克服噪声,同时也能简化树使之更易于理解。剪枝类型主要包括:

(1) 向前剪枝(forward pruning)在生成树的同时决定是继续对不纯的训练子集进行划分还是停机。

(2) 向后剪枝(backward pruning)是一种两阶段法,即拟合-化简(fitting and simplifying),首先生成与训练样本完全拟合的一棵决策树,然后从树的叶子开始剪枝,逐步向根的方向剪。

但是,剪枝也存在一定局限性。剪枝并不是对所有的数据集都适用,正如最小的树并不是最好(具有最大的预测率)的树。当数据稀疏时,应防止过分剪枝(overpruning)。从某种意义而言,剪枝也是一种偏向,对有些数据集效果好而有些则效果较差。

## 7.3 实现过程

分类的实现过程一般分为两个步骤。

### 1. 通过训练集建立分类模型(即建模)

建模一般分为训练和测试两个阶段。建模之前,要求将数据集划分为训练集和测试集,并对每个样本进行类别标记,即预设分类类别。训练阶段,通过分析由属性描述的训练样本构造模型。该阶段也称为有指导的学习,通常模型为分类规则、判定树或数学公式的形式;测试阶段,使用测试集评估模型分类的准确率,如果认为模型的准确率可以接受,则使用该模型对类别未知的待分类样本进行分类。一般而言,测试阶段的代价远低于训练阶段。

为了提高分类的准确性、有效性和伸缩性,建模前,通常需要预处理,具体包括:

- (1) 数据清理。其目的是消除或减少噪声,处理缺失值。
- (2) 相关性分析。由于数据集的许多属性可能与分类不相关,若包含这些属性将减慢或可能误导学习过程。相关性分析的目的是删除不相关或冗余的属性。
- (3) 数据变换。数据可以抽象到较高层次。例如,属性“收入”的连续值可以抽象为离散值,如低、中和高。此外,还可以规范化,即将属性值按比例缩放落入较小的区间,

如 $[0,1]$ 。

构建分类模型的过程如图 7.6 所示。

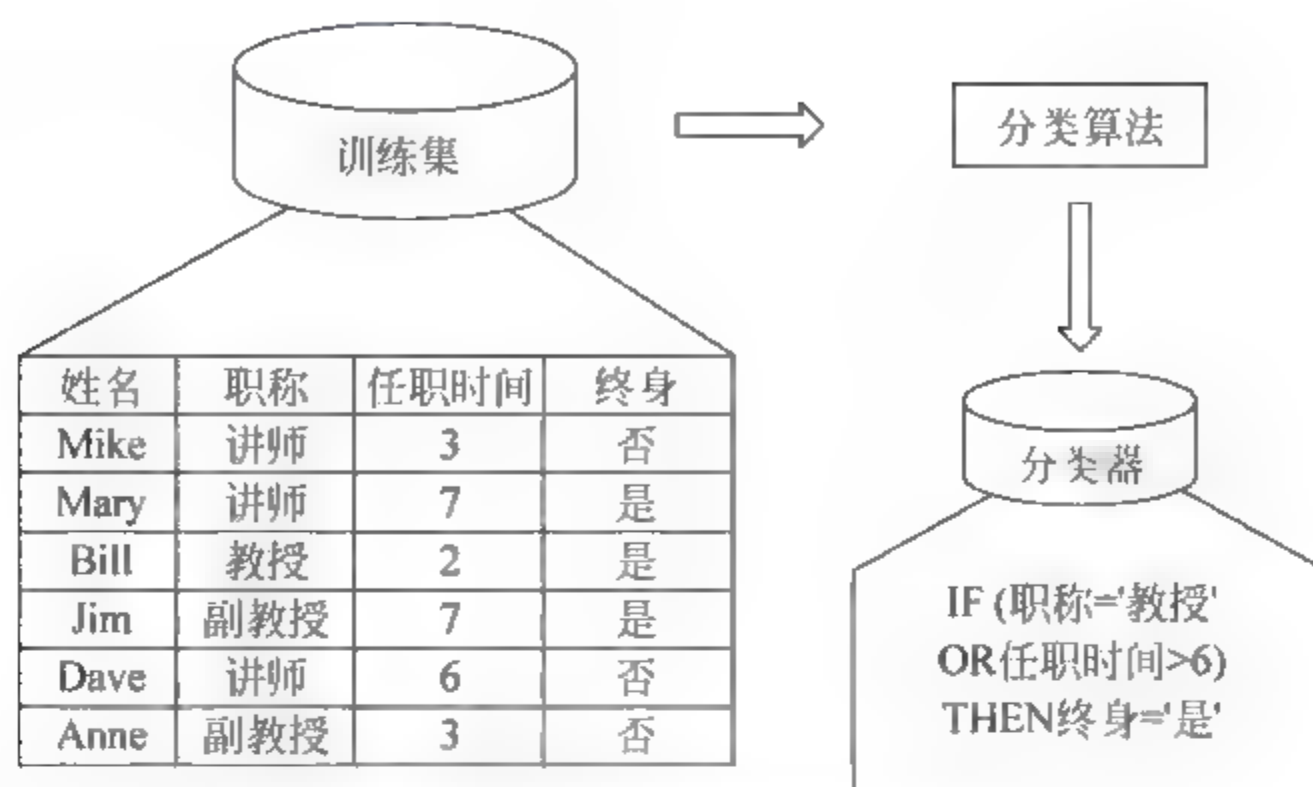


图 7.6 构建分类模型的过程

## 2. 利用已训练好的分类模型识别类型未知的对象(即使用模型)

测试集与训练集互相分离,否则将出现过度拟合(overfitting)现象。使用分类模型的过程如图 7.7 所示。

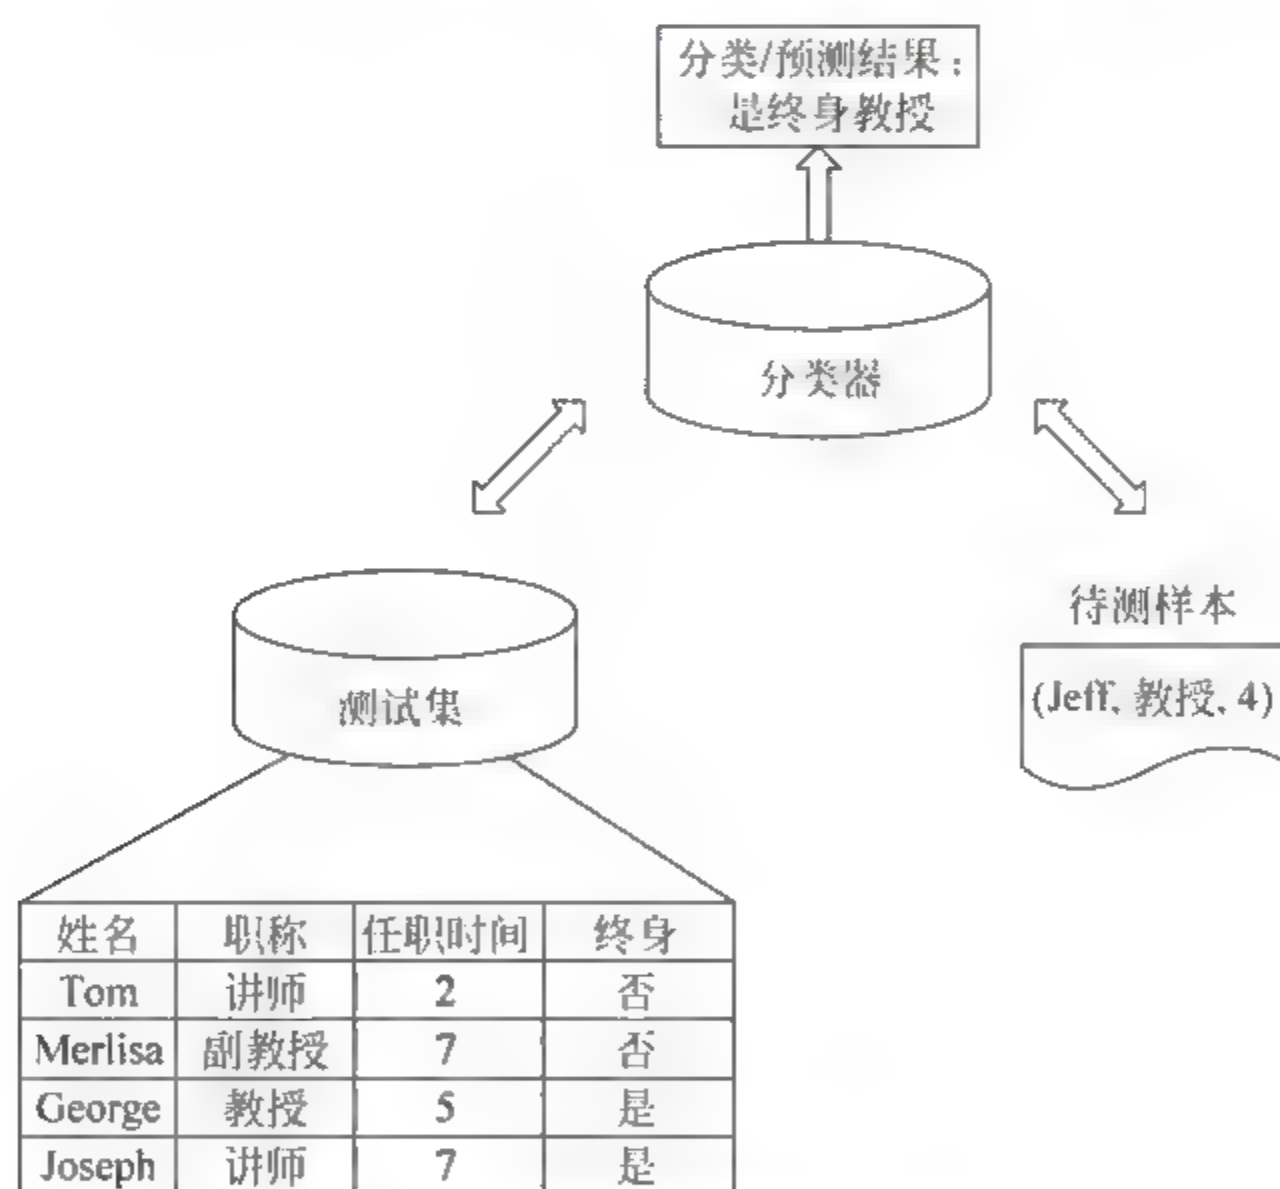


图 7.7 使用分类模型的过程



## 第8章 关联分析

### 8.1 概述

自然界中某一事物发生时其他事物也会发生,这种联系称之为关联。反映事件之间依赖或关联的知识称为关联型知识(又称依赖关系)。关联是指两个或多个变量取值之间存在的某种重要的可被发现的规律性,分为简单关联、时序关联和因果关联等。

以交易型数据库为例,一个交易一般由交易处理时间,一组顾客购买的物品,有时也包括顾客标识(如信用卡号)等组成。关联规则可描述在一次交易中物品之间同时出现的规律。更确切地说,关联规则量化地描述了物品  $X$  出现对物品  $Y$  出现有多大的影响。

例如,体育用品商店通过对销售数据的关联分析发现这些数据中常常隐含这样的规律,即“购买篮球的顾客中有 70% 的人同时购买篮球运动服,所有交易中有 40% 的人同时购买篮球和篮球运动服”等,这些规律即关联规则。

另一个典型例子是购物篮的分析。通过发现顾客放入其购物篮中不同商品之间的联系,进一步分析顾客的购买习惯,帮助零售商制定针对性的营销策略,如合理地安排货架以引导销售,将牛奶和面包尽可能放近一些,以刺激一次购物同时购买多种商品。

频繁项集(frequent itemset)是产生关联规则的基础,因此在定义关联规则之前首先介绍频繁项集的定义及其性质。

**定义 8.1** 设  $I$  为一个由  $m$  个项组成的集合  $I = \{i_1, i_2, \dots, i_m\}$  称为项集(itemset)。

交易  $T$  是由  $I$  中的项组成的子集,即  $T \subset I$ 。与集合的定义一样,交易  $T$  中同样不存在重复的元素。假设这里所涉及的交易和项集的项都已排序。

如果交易  $T$  包含项集  $X$  中的所有项,即  $X \subset T$ ,则称  $T$  支持  $X$ 。 $T(X)$  定义为所有支持  $X$  的交易组成的集合。

**定义 8.2** 数据库  $D$  中支持项集  $X$  的交易所占的比例称为  $X$  在  $D$  中的支持度,记为  $\text{supp}(X)$  或  $S(X)$ 。

设  $\text{minsup}$  为给定的最小支持度,如果  $\text{supp}(X) \geq \text{minsup}$ ,则称项集  $X$  是频繁的。一个项集的最小支持度是该项集被认为是有意义的,支持它的交易占数据库  $D$  中所有交易总和的最小比例,通常是根据经验设定,不具有最小支持度的项集被认为是没有意义的。

**定义 8.3** 项集包含项的个数称为长度或基数。长度为  $k$  的项集称为  $k$  ( $k = |X|$ ) 维项集,记为  $k$  itemset。

频繁项集具有以下三种性质,其中性质 8.1 和性质 8.3 是所有分析规则算法的基础。

**性质 8.1: 子集支持**

设  $A$  和  $B$  是两个不同的项集,如果  $A \subset B$ ,则  $\text{supp}(A) \geq \text{supp}(B)$ 。因为所有支持  $B$  的交易也一定支持  $A$ 。

**性质 8.2: 非频繁项集的超集也一定是非频繁的**

如果  $A$  满足最小支持度条件,即  $\text{supp}(A) < \text{minsup}$ ,则  $A$  的每个超集  $B$  也不是频繁



的。由性质 8.1 可得  $\text{supp}(B) \leq \text{supp}(A) \leq \text{minsup}$ , 因此  $B$  也是非频繁的。

**性质 8.3:** 频繁项集的子集也是频繁的。

如果项集  $B$  是数据库  $D$  中的频繁项集, 即  $\text{supp}(B) \geq \text{minsup}$ , 则  $B$  的每个子集  $A$  也是频繁的。由性质 8.1 可得  $\text{supp}(A) \geq \text{supp}(B) \geq \text{minsup}$ , 因此  $A$  也是频繁的。特别地, 如果  $A$  是频繁的, 则其  $k$  个基数为  $k-1$  的子集都是频繁的; 反之则不成立。

设  $I = \{i_1, i_2, \dots, i_m\}$  是有  $m$  个不同元素的集合,  $T$  是针对  $I$  的交易集合, 每一笔交易包含若干个属于  $I$  的项。关联规则表示为  $X \Rightarrow Y$ , 其中  $X$  和  $Y$  是两个不相交的集合,  $X, Y \subset I$  并且  $X \cap Y = \emptyset$ 。  $X$  称为规则的前提或前项,  $Y$  称为规则的结果或后项。每个规则都有两个度量, 即支持度(support)和可信度(confidence)。其中,

- 支持度定义为  $\text{support}(X \Rightarrow Y) = \text{support}(X \cup Y)$ 。
- 可信度定义为  $\text{confidence}(X \Rightarrow Y) = \text{support}(X \cup Y) / \text{support}(X)$ 。
- 关联规则的形式为  $R: X \Rightarrow Y$ 。

关联规则具有以下四种性质。

**性质 8.4:** 规则的非结合性。

如果关联规则  $X \Rightarrow Z$  和  $Y \Rightarrow Z$  在  $D$  中成立, 规则  $X \cup Y \Rightarrow Z$  不一定在  $D$  中成立。如果  $X \cap Y = \emptyset$ , 并且  $D$  中支持  $Z$  的所有交易都只支持  $X$  或  $Y$ , 则集合  $X \cup Y \cup Z$  的支持度为 0, 因此  $X \cup Y \Rightarrow Z$  的可信度为 0。

类似地, 如果规则  $X \Rightarrow Y$  和  $X \Rightarrow Z$  成立, 规则  $X \Rightarrow Y \cup Z$  不一定成立。

**性质 8.5:** 规则的不可分解性。

如果关联规则  $X \cup Y \Rightarrow Z$  在  $D$  中成立, 规则  $X \Rightarrow Z$  和  $Y \Rightarrow Z$  不一定在  $D$  中成立。例如, 当  $Z$  只出现在一个交易时, 如果  $X$  和  $Y$  也出现在其中, 即  $\text{supp}(X \cup Y) = \text{supp}(Z)$ , 规则就是不可分解的。另外, 如果  $X$  与  $Y$  的支持度与  $XY$  的支持度相比足够大, 就会使得分解后的两个规则不具有所要求的可信度, 因此规则也不可分解。

因为  $\text{supp}(X \cup Y) \geq \text{supp}(X \cup Y \cup Z)$  且  $\text{supp}(X \cup Z) \geq \text{supp}(X \cup Y \cup Z)$ , 所以如果规则  $X \Rightarrow Y \cup Z$  成立, 则规则  $X \Rightarrow Y$  和  $X \Rightarrow Z$  都成立。由此可得较小规则的支持度与可信度与原规则相比都有所增大。

**性质 8.6:** 规则的不可传递性。

由关联规则  $X \Rightarrow Y$  和  $Y \Rightarrow Z$  成立不能推导出规则  $X \Rightarrow Z$  成立。设  $T(X) \subset T(Y) \subset T(Z)$ , 最小可信度为  $\text{minconf}$ ,  $\text{conf}(X \Rightarrow Y) = \text{conf}(Y \Rightarrow Z) = \text{minconf}$ 。

$$\begin{aligned} \text{由 } T(X) \subset T(Y) \text{ 可得 } \text{conf}(X \Rightarrow Y) &= S(X \cup Y) / S(Y) \\ &= S(X) / S(Y) = \text{minconf} \end{aligned}$$

$$\begin{aligned} \text{由 } T(Y) \subset T(Z) \text{ 可得 } \text{conf}(Y \Rightarrow Z) &= S(Y \cup Z) / S(Z) \\ &= S(Y) / S(Z) = \text{minconf} \end{aligned}$$

$$\text{由 } T(X) = T(Z) \text{ 可得 } \text{conf}(X \Rightarrow Z) = S(X \cup Z) / S(Z) = S(X) / S(Z)$$

由上面三个等式和  $\text{minconf} < 1$ , 可得  $\text{conf}(X \Rightarrow Z) = \text{minconf} < \text{minconf}$ 。因此规则  $X \Rightarrow Z$  不成立。

**性质 8.7:** 规则的可扩展性。

设项集  $L, A$  和  $B$ , 且  $B \subset A \subset L$ , 如果规则  $A \Rightarrow (L - A)$  不满足最小可信度条件, 则



$B \rightarrow (L-B)$ 也不满足最小可信度条件。由性质 8.1 可得  $\text{supp}(B) \geq \text{supp}(A)$ , 再由可信度的定义可得  $\text{conf}(B \rightarrow (L-B)) = \text{supp}(L)/\text{supp}(B) \leq \text{supp}(L)/\text{supp}(A) < \text{minconf}$ 。

同理可得, 对项集  $L$ 、 $D$  和  $C$ , 且  $D \subset C \subset L, D \neq \emptyset$ , 如果规则  $(L-C) \rightarrow C$  成立, 则规则  $(L-D) \rightarrow D$  也成立。

当所有频繁项集及其支持度确定后, 利用性质 8.7 可以加速规则的产生。

关联分析旨在发现支持度或可信度分别大于设定的最小支持度值和最小可信度值的规则。本质上, 关联分析分解成:

(1) 产生所有支持度大于或等于设定最小支持度的项集, 这些项集称为频繁项集, 而其他的项集则称为非频繁项集。

(2) 对于每个频繁项集, 产生可信度大于或等于最小可信度的规则, 即对于一个频繁项集  $L$  及任意  $S \subset L$ , 如果  $\text{support}(L)/\text{Support}(S) \geq \text{minconf}$ , 则规则  $S \rightarrow (L-S)$  就是一个正确规则。

关联分析的主要算法包括 R. Agrawal 等提出的 AIS(Artificial Immunity System, 人工免疫系统)、Apriori 及其变种 AprioriTid 和 AprioriHybrid; M. Houtsma 等提出的 SETM; J. Park 等提出的 DHP; A. Savasere 等提出的 PARTITION; H. Toivonen 提出的 Sampling 和 Jiawei Han 提出的 FP-Growth 等。

AIS 算法的主要思想是在扫描数据库的同时产生候选项集并累计支持度。具体地, 在对数据库进行第  $k$  次扫描时, 候选项集是由第  $k-1$  次扫描所产生的边界集通过增加当前事务中的项得到, 同时计算候选项集元素的支持度, 直到某次扫描所产生的边界集为空。其主要缺点是生成的候选项集过大。

SETM 算法实际上是 AIS 算法的变种, 把候选项集的产生和累计分开。在一个线性存储结构中存储了所有候选项集和相应交易的标识符(TID)。每次扫描结束后, 不再读取数据库, 而是对 TID 进行排序并累计各个候选项集的支持度。其主要思想是通过扫描候选项集的编码代替扫描数据库, 实质上是把数据库中与支持度有关的信息单独提取出来, 构成一个较小但充分的 TID 库, 这大大减少了数据库的访问时间, 不足之处同样是候选项集过大。

Apriori 算法利用项集的性质对数据库进行多次扫描, 即任意频繁项集的子集都是频繁项集; 任意非频繁项集的超集都是非频繁项集。第一次扫描数据库得到频繁 1 项集  $L_1$ , 第  $k$  次扫描前先利用上次扫描结果, 即项集  $L_{k-1}$ , 产生候选的  $k$  项集的集合  $C_k$ , 然后再通过扫描数据库确定对  $C_k$  中每一候选  $k$  项集的支持度, 最后在该次扫描结束时得到频繁  $k$  项集  $L_k$ , 算法在  $C_k$  或  $L_k$  为空时终止。Apriori 算法产生的候选项集比 AIS 算法少得多, 效率较高。Apriori 是关联分析的经典算法, 很多算法都是其变种或改进。

DHP 算法利用散列表(Hash table)产生候选项集, 是对 Apriori 算法的直接改进。在遍历一次数据库得到候选  $k$  项集的支持度, 得到频繁  $k$  项集后, 将每一个事务的可能的  $(k+1)$  项集通过哈希规则形成散列表。散列表的每一栏包括所有通过散列规则映射到该栏的项集的数目。根据结果的散列表, 可以生成一个位向量, 当散列表中对应该栏的值大于或等于最小支持度时, 对应的位置为 1, 否则为 0。利用该向量可以过滤掉下一次生成不必要的候选项集, 即如果某候选项在向量中对应位置的值为 0, 则舍弃, 这对候选 2 项集的产生尤为有效, 可以在第二次扫描时就大大减小候选项集的规模。在某些场合, DHP 的效率比 Apriori 明显提高。



PARTITION 算法主要针对大型数据库,分为两个步骤其一·是将目标数据库划分为  $n$  个互不相交的子数据库  $D_1, D_2, \dots, D_n$ , 每个  $D_i (i=1, 2, \dots, n)$  都存储在内存中。然后逐一把  $D_i$  读入内存并按一般算法发现频繁项集  $L_i$ ; 再把所有的  $L_i$  合并为数据库的潜在频繁项集; 其二计算潜在频繁项集在数据库中的支持度, 得到频繁项集  $L$ 。

Sampling 算法的主要思想是对数据库  $D$  进行随机抽样得到抽样数据库  $D'$ , 先以小于指定的最小支持度找到  $D'$  的频繁项集  $L'$ , 再在剩余数据集  $D-D'$  中继续计算  $L$  中各元素的支持度, 最后再以最小支持度求出  $L$ 。对于大部分情况可以得到所有的频繁项集, 但有时会漏掉一些。可以对数据库进行二次扫描得到漏掉的频繁项集。多数情况下, 此算法只需对数据库扫描一次, 最坏也只需扫描两次。

FP-Growth 算法主要是采用一种新的数据结构 FP-tree, 克服 Apriori 算法产生候选项集的缺点。该算法只扫描数据库两次, 并且不用产生候选项集, 提高了效率。

下面着重介绍 Apriori 和 FP-Growth 两种算法。

## 8.2 Apriori

R. Agrawal 等在 1994 年提出了著名的 Apriori 算法, 它是一种最有影响的挖掘布尔关联规则频繁项集的算法, 得名于算法使用了频繁项集性质的先验知识。

Apriori 包含由候选项集(candidate itemset)产生频繁项集(frequent itemset), 由频繁项集产生强关联规则(strong association rule)两个步骤。

Apriori 使用逐层搜索的迭代方法, 通过对数据库的多次扫描发现所有的频繁项集。在每一次扫描中只考虑具有同一长度  $k$  (即项集中所含项的个数) 的所有项集。算法的第一次扫描仅仅计算每个项具体值的数量, 确定长度为 1 的频繁项集。在后继的每次扫描中, 首先使用前一次扫描中找到的频繁项集  $L_{k-1}$  和 Apriori-gen 函数产生候选项集  $c_k$ , 接着扫描数据库, 计算  $C_k$  中候选项集的支持度, 最后确定哪些候选项集成为真正的频繁项集。重复上述过程直到再没有新的频繁项集出现。

Apriori 算法中, 使用逐层迭代找出频繁项集的过程描述如下:

输入: 事务数据库  $D$ , 最小支持度阈值

输出:  $D$  中的频繁项集  $L$

```

1  Begin
2  L1 = (large 1-itemset);           /* 生成含有 1 项的频繁集 */
3  For (k = 2; Lk-1 ≠ ∅; k++) Do
4  Begin
5      Ck = apriori-gen(Lk-1);
6      For all transition t ∈ D Do
7      Begin
8          Ct = subset (Ck, t);       /* 产生事务 t 中包含的 k 项集 Ct */
9          For all Candidate c ∈ Ct Do
10             c.count++;             /* 计数 */
11         End;
12         Lk = {c ∈ Ck | c.count ≥ min sup}
13     End;
14 Answer = Lk;
15 End
    
```



产生候选项集的过程描述如下:

假定  $L_{k-1}$  中各项按某一次序排列,候选项集的产生由以下两个步骤组合而成,即:

连接步骤: Apriori-gen( $L_{k-1}$ )的连接

Begin

insert into  $C_k$

select p.item1, p.item2, ..., p.item $k-1$ , q.item $k-1$

from  $L_{k-1}$ , p,  $L_{k-1}$ , q

where p.item1 = q.item1, p.item2 = q.item2, ..., p.item $k-2$  = q.item $k-2$ , p.item $k-1$  < q.item $k-1$ ;

End;

剪枝步骤: Apriori-gen 的剪枝

For all itemsets  $c \in C_k$  Do

For all  $(k-1)$ -subsets  $s$  of  $c$  Do

if ( $s$  不属于  $L_{k-1}$ ) then

delete  $c$  from  $C_k$ ;

Apriori 首先产生频繁 1 项集  $L_1$ , 然后是频繁 2 项集  $L_2$ , 直到有某  $r$  值使得  $L_r$  为空则算法停止。其中第  $k$  次循环中, 首先产生候选  $k$  项集的集合  $C_k$ ,  $C_k$  中的每一个项集是对两个只有一项不同的属于  $L_{k-1}$  的频繁项集做一个  $(k-2)$  连接产生的。 $L_1$  中的项集是用来产生频繁项集的候选项集, 最后的频繁项集  $L_k$  必须是  $C_k$  的一个子集。 $C_k$  中的每个元素需在交易数据库中进行验证决定其是否加入  $L_k$ , 这里的验证过程是算法性能的一个瓶颈。这一方法要求多次扫描可能很大的交易数据库。Apriori-gen 的剪枝算法用来删除候选  $L_k$  中项集的子集不是频繁项集的集合。

对于具有一定规模的事务数据库而言, 其蕴含的候选项集数量特别巨大, 同时一个事务内部也可能蕴含许多的候选项集, 这些成为制约 Apriori 算法性能的主要因素。

下面通过一个实例说明 Apriori 算法的实现过程。

(1) 设一个小型的交易数据库  $D$ , 如表 8.1 所示, 设定最小支持度阈值为 2。

(2) 扫描数据库  $D$ , 对每个候选项计数生成  $C_1$ , 如表 8.2 所示。

表 8.1 交易数据库  $D$

交 易 号	项 集 合
T1	I1, I2, I5
T2	I2, I4
T3	I2, I3
T4	I1, I2, I4
T5	I1, I3
T6	I2, I3
T7	I1, I3
T8	I1, I2, I3, I5
T9	I1, I2, I3

表 8.2  $C_1$

项 集	支持度计数
{I1}	6
{I2}	7
{I3}	6
{I4}	2
{I5}	2

(3) 比较候选项支持度计数与最小支持度阈值, 生成  $L_1$ , 如表 8.3 所示。

(4) 由  $L_1$  产生候选项集  $C_2$ , 如表 8.4 所示。

表 8.3  $L_1$

项 集	支持度计数
{I1}	6
{I2}	7
{I3}	6
{I4}	2
{I5}	2

表 8.4  $C_2$

项 集	项 集
{I1,I2}	{I2,I4}
{I1,I3}	{I2,I5}
{I1,I4}	{I3,I4}
{I1,I5}	{I3,I5}
{I2,I3}	{I4,I5}

- (5) 再次扫描数据库  $D$ ,对每个候选项计数产生  $L_2$ ,如表 8.5 所示。  
(6) 对  $L_2$  进行连接和剪枝,产生  $C_3$  即最终结果,如表 8.6 所示。

表 8.5  $L_2$

项 集	支持度计数
{I1,I2}	4
{I1,I3}	4
{I1,I5}	2
{I2,I3}	4
{I2,I4}	2
{I2,I5}	2

表 8.6  $C_3$

项集
{I1,I2,I3}
{I1,I2,I5}

下面介绍  $L_2$  的连接与剪枝产生  $C_3$  的过程。

① 连接运算

$$C_3 = L_2 \circ L_2$$
$$= \{ \{I1,I2\}, \{I1,I3\}, \{I1,I5\}, \{I2,I3\}, \{I2,I4\}, \{I2,I5\} \} \circ \{ \{I1,I2\}, \{I1,I3\}, \{I1,I5\}, \{I2,I3\}, \{I2,I4\}, \{I2,I5\} \}$$
$$= \{ \{I1,I2,I3\}, \{I1,I2,I5\}, \{I1,I3,I5\}, \{I2,I3,I4\}, \{I2,I3,I5\}, \{I2,I4,I5\} \}$$

② 剪枝运算

{I1,I2,I3}的 2 项子集是{I1,I2}、{I1,I3}和{I2,I3}。  
{I1,I2,I3}的所有 2 项子集都是  $L_2$  的元素。因此,保留{I1,I2,I3}在  $C_3$  中。  
{I2,I3,I5}的 2 项子集是{I2,I3}、{I2,I5}和{I3,I5}。  
{I3,I5}不是  $L_2$  的元素,因而不是频繁的。因此,删除  $C_3$  中的{I2,I3,I5}。  
以此类推,剪枝后  $C_3 = \{ \{I1,I2,I3\}, \{I1,I2,I5\} \}$ 。

Apriori 算法的另一个实例如图 8.1 所示,其中最小支持度阈值设定为 2。

Apriori 算法利用候选项集和频繁项集的相互作用,得到全部频繁项集,并通过对候选项集的剪枝,大大减少了候选项集的大小,获得了令人满意的结果。然而,当面对挖掘对象具有众多的频繁模式、长模式或者用户给定的最小支持度的阈值较低时,Apriori 算法仍然可能因为以下两个方面的巨大开销而面临困境。

(1) 在处理大量的候选项集方面,如果算法得到了大量的频繁 1 项集  $L_1$ ,则在产生  $C_2$  时,会遇到大量  $C_2$  难以处理的情况。例如假设算法得到的频繁 1 项集  $L_1$  的数量是  $10^4$ ,则根据 Apriori 算法,产生的 2 项候选集数量超过  $10^7$ ,由于候选项集  $C_2$  没有剪枝,所有候选项集都需要检验。此外,在面对频繁模式的大小较大时,同样会产生大量的候选项集需要检



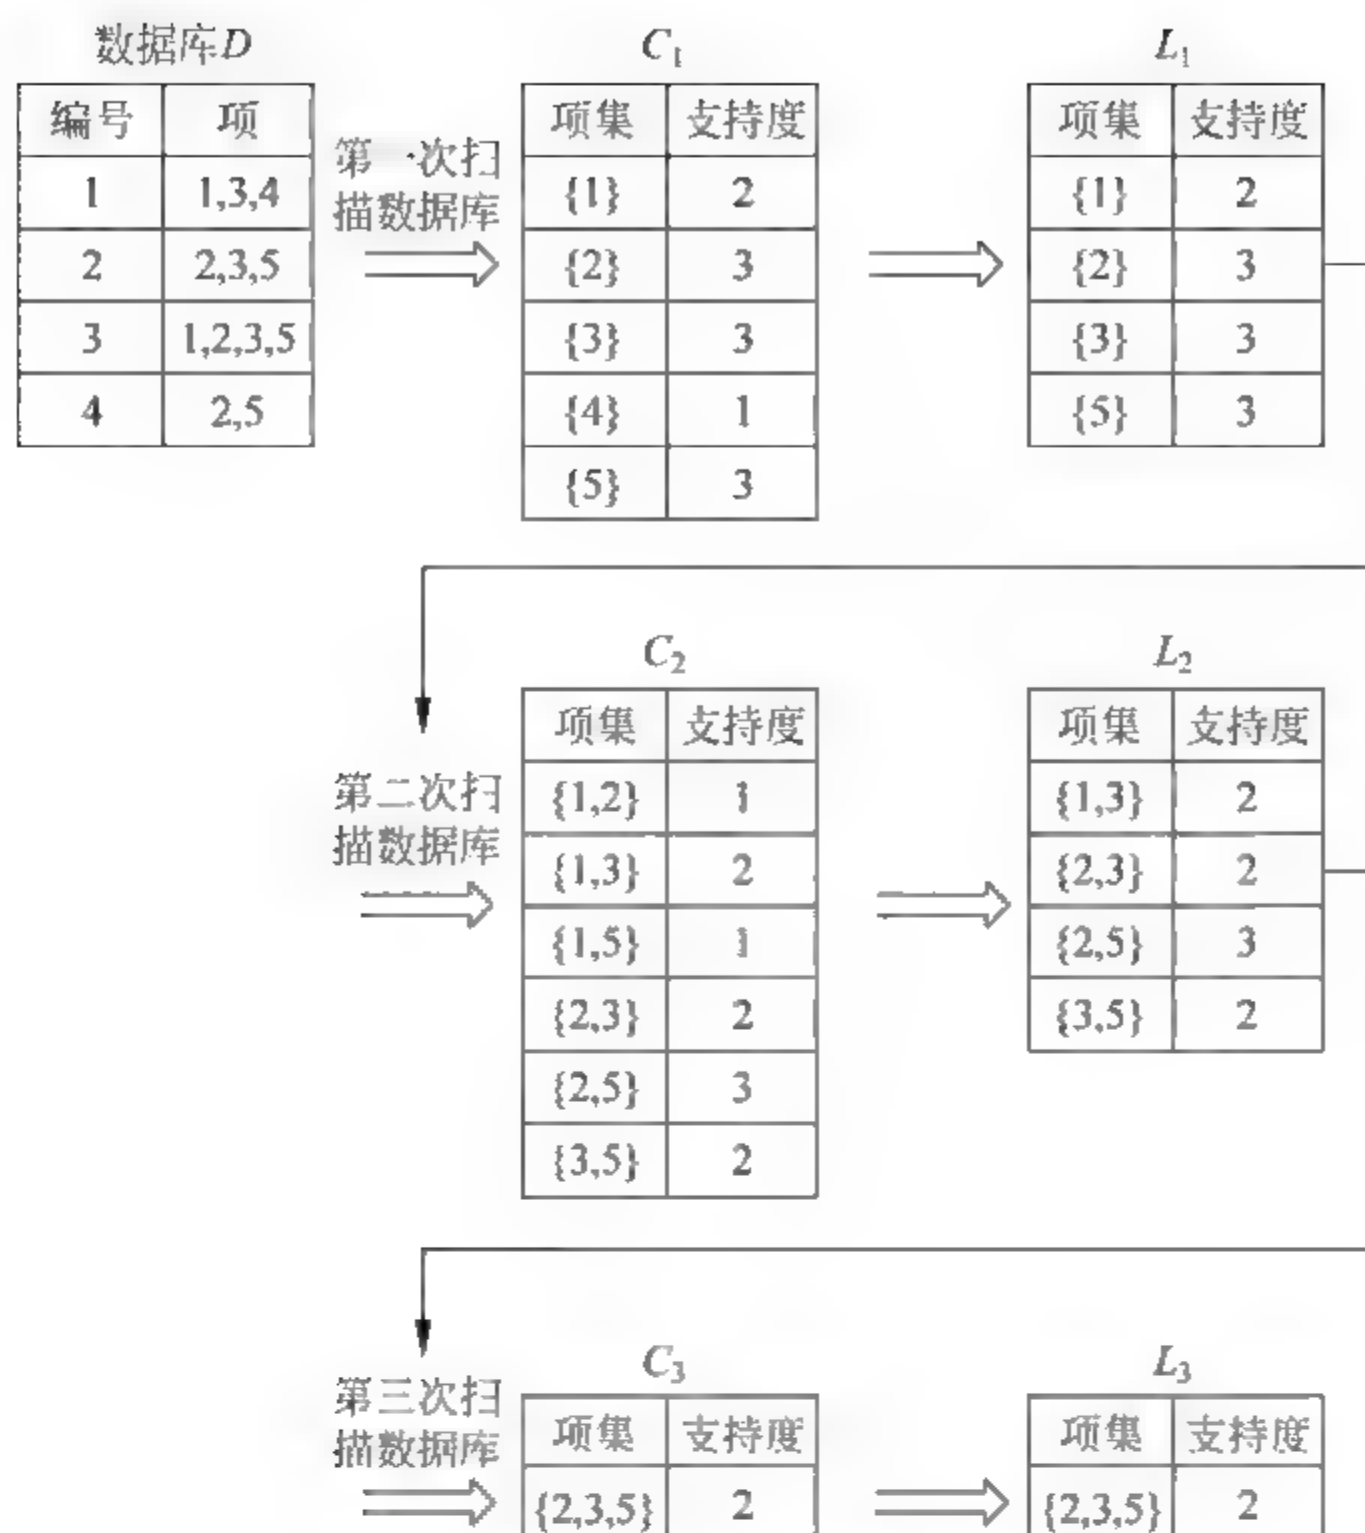


图 8.1 Apriori 算法实例

验。在内存等其他条件均为理想状态的情况下,这种由产生候选项集的方法所决定的开销,无论采用什么实现技术都无法回避。所以,在有大量候选项集产生的情况下,Apriori 算法基本无法运行。

(2) 采用的模式匹配方式,在检测大量的候选项集,特别是长模式时,对数据库的重复扫描非常费时,大量时间消耗在内存与数据库的数据交换上。

由于上述原因,可以发现 Apriori 算法的瓶颈是候选项集的产生和测试过程。如果有一种算法能够对产生的大量候选项集进行有效的控制,将会极大地减少时间开销。

由于依赖从候选项集产生频繁项集的 Apriori 类算法具有先天的弱点,使得 Apriori 类算法的应用没有实质性突破。Jiawei Han 等提出了一种采用压缩的数据结构(FP tree)存储关联规则挖掘所需的全部数据的新方法,通过对源数据的两次扫描,将数据存储到 FP tree 结构,避免产生候选项集,极大地减少了数据交换和频繁匹配的开销,即所谓的无候选项集产生算法(Frequent Patterns Growth, FP Growth)。

### 8.3 FP-Growth

FP Growth 克服必须产生候选项集的限制,提出了关联规则挖掘的新思路,主要改进体现在:

(1) 构造一种新颖的、紧凑的数据结构 FP tree。它是一种扩展的前缀树结构,存储关

于频繁模式数量的重要信息。树中只包含长度为 1 的频繁项作为叶结点,并且那些频度高的结点更靠近树的根结点,因此频度高的项比那些频度低的项有更多的机会共享同一个结点。

(2) 开发基于 FP-tree 的模式片断成长算法,从长度为 1 的频繁模式开始,只检查其条件模式及构建的条件模式树,并且在这个树上递归地执行挖掘。模式的成长通过联合条件模式树新产生的后缀模式实现。由于事务处理中的频繁项都对应着频繁树中的路径进行编码,模式的成长确保了结果的完整性。因此,FP-Growth 不像 Apriori 那样需要产生再测试,挖掘的主要操作是计算累加值和调整前缀树,这种开销通常远远小于 Apriori 类算法中的候选项集的产生和模式匹配操作。

(3) 采用基于分区的搜索。通过分割,而不是 Apriori 类算法的自下向上产生频繁模式的集合。将发现长频繁模式的问题转化为寻找短模式然后再与后缀连接的方法,避免了产生长候选项集。

FP-tree 的结构包括一个标识为 Null 的根、一个由频繁项组成的头表和一组项的前缀子树组成根的子孙。树中的每个结点包括项名(itemname)、计数(count)和结点链接(node Link)三个域。其中,项名标识结点所代表的项;计数标识树中到达该结点的路径所代表的事务处理的数目;结点链接指向树中下一个同名结点,如果没有同名结点则指向空。头表的每条记录包含两个域,即项名和结点链接的头。结点链接的头指向树中第一个同名的结点。

FP-tree 只保存满足最小支持度的项的集合。所以,首先需要知道哪些项符合条件,即构造头表。对数据库进行第一次扫描得到满足最小支持度的项并按降序排列在头表中。在得到头表之后,对源数据进行第二次扫描,对每个事务处理包含的频繁项按照其在头表的先后顺序插入到树。插入到树的事务处理的频繁项自然是树的一个路径,但如果树中存在其他与新路径完全相同或部分相同的路径,则需要将两个路径全部或部分合并,将事务处理插入到 FP-tree 中的函数 insert-tree([p/P],T)是算法中一个非常关键的部分。

FP tree 是一个高度压缩的结构,存储用于频繁模式挖掘的全部信息,由于一个以  $a_1$  作为前缀的单一路径  $a_1 \rightarrow a_2 \rightarrow \dots \rightarrow a_k$  代表所有那些最大的频繁集形式为  $a_1 \rightarrow a_2 \rightarrow \dots \rightarrow a_k$  ( $1 \leq k \leq n$ ) 的事务处理,所以 FP tree 远远小于源数据和在关联规则挖掘过程中产生的候选项集的大小。同时,频繁集中的项以支持度降序排列,支持度越高的项与 FP tree 树根越接近,因此有更多的项是共享的。

FP-Growth 算法描述如下:

#### 1. 构造 FP-tree

扫描数据库一次。得到频繁项的集合  $F$  和其支持度,按照支持度对  $F$  降序排序,产生频繁项表  $L$ 。

创建 FP tree 的根结点,标记为 Null。对于数据库的每一个事务,选择频繁项,并按  $L$  中的次序排序。设排序后的频繁项表为  $[p/P]$ ,其中  $P$  是第一个元素,而  $T$  是剩余元素的表。调用 insert tree([p/P],T)。该过程执行情况如下:如果  $T$  有子女  $N$  使得  $N.item\ name = p.item\ name$ ,则  $N$  的计数加 1;否则创建一个新结点  $N$ ,将其计数设置为 1,链接到其父结点  $T$ ,并且通过结点链结构将其链接到具有相同项名的结点;如果  $P$  非空,递归调用 insert tree( $P,N$ )。



## 2. 在 FP 树中挖掘频繁模式

输入：事务数据库  $D$  的 FP 树和最小支持度阈值  $\text{minsup}$ 。

输出：所有频繁模式的集合。

方法：调用  $\text{FP-Growth}(\text{FP-Tree}, \text{null})$ 。

Procedure  $\text{FP-Growth}(\text{Tree}, \alpha)$

if (Tree 只包含单路径  $P$ ) then

    对路径  $P$  中结点的每个组合 (记为  $\beta$ )

    生成模式  $\beta \cup \alpha$ , 支持度 =  $\beta$  中所有结点的最小支持度

else 对 Tree 头上的每个  $a_i$  do

    生成模式  $\beta = a_i \cup \alpha$ , 支持度 =  $a_i$ . support;

    构造  $\beta$  的条件模式库和  $\beta$  的条件 FP 树  $\text{Tree}_\beta$ ;

    if  $\text{Tree}_\beta \neq \phi$

    then call  $\text{FP-Growth}(\text{Tree}_\beta, \beta)$

这是一个递归调用函数, 根据 FP-tree 的属性和上述的引理和推论, 对于给定的数据源和支持度阈值, 算法可以获得所有满足条件的频繁项集合。

假设最小支持度阈值为 0.5, 交易数据库如表 8.7 所示。

表 8.7 交易数据库

交易编号	购物项	排序后的频繁项
100	f,a,c,d,g,i,m,p	f,c,a,m,p
200	a,b,c,f,l,m,o	f,c,a,b,m
300	b,f,h,j,o	f,b
400	b,c,k,s,p	c,b,p
500	a,f,c,e,l,p,m,n	f,c,a,m,p

第一次扫描数据库, 得到频繁 1 项集, 然后按照频度的降序排列。再次扫描数据库, 生成的 FP-tree 如图 8.2 所示。

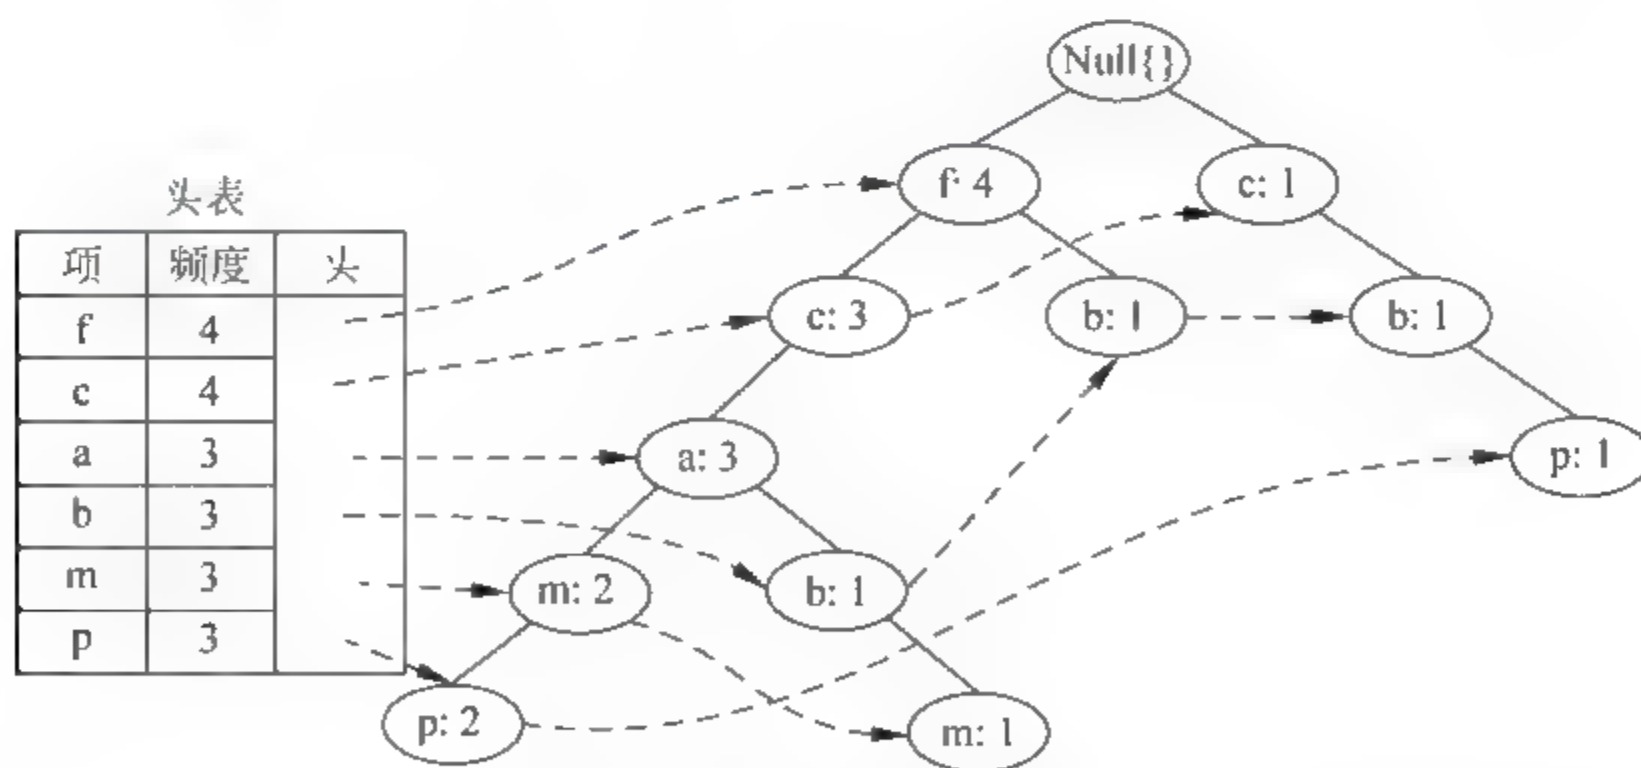


图 8.2 生成的 FP-tree

由图 8.2 可知, 对任意频繁项  $a_i$ , 顺着  $a_i$  的结点链, 从  $a_i$  的头开始, 可以找到包含  $a_i$  的所有频繁模式。

## 第9章 Web 挖掘

随着 Internet 的飞速发展,数以亿计的静态网页和动态网页汇聚了人类无穷的智慧,海量 Web 数据包含了无数的链接、访问路径和丰富的内容。据统计,目前全世界将近 90% 的信息是 Web,而且其数量和重要性仍与日俱增。Web 数据具有异构、半结构化和动态等特点。

### 1. 异构

从数据库的角度,Web 信息也可以看做一个数据库,一个更大、更复杂的数据库。每一个 Web 站点就是一个数据源,每个数据源都是异构的,因而每一站点的信息和组织都不一样,这就构成了一个巨大的异构数据库环境。如果想利用这些 Web 进行挖掘,首先,必须要研究异构 Web 数据的集成问题,只有将它们集成起来提供给用户一个统一的视图,才有可能从巨大的 Web 资源中获取所需的東西。其次,还要解决 Web 查询问题,因为如果所需的 Web 不能有效地得到,对它们的分析、集成、处理就无从谈起。

### 2. 半结构化

Web 与传统数据库中的数据不同,传统的数据库都具有一定的数据模型,可以根据模型具体描述特定的数据。而 Web 数据非常复杂,没有特定的模型描述,每一站点的 Web 都各自独立,并且数据本身具有自述性和动态可变性。因而,Web 虽具有一定的结构性,但因自述层次的存在,从而是一种非完全结构化数据,称之为半结构化数据。半结构化是 Web 数据的最大特点。

### 3. 动态性

Web 数据不仅每天都以极快的速度增长,而且也在不断地动态变化。因此需要借助数据仓库技术,以保存动态更新的 Web 数据。

综上所述,从海量 Web 中真正发现知识存在一定的困难,主要体现在:

- (1) Web 数量太庞大,例如 Web Informall 达 15T,而且仍在迅速增加。
  - (2) Web 复杂性高于任何传统的文本,例如 Web 分类需要预处理,Web 缺乏统一的结构。Web 可以看作一个巨大的数字图书馆,而这一图书馆中的大量信息并没有按照任何排序进行组织,没有分类索引,更没有标题、作者扉页和口次等索引,在其中搜索所需信息极具挑战性。
  - (3) Web 面向广泛的用户群,且仍在不断地扩展。不同用户具有不同的背景、兴趣和使用目的。大部分用户并不了解信息的结构,不清楚搜索的高昂代价,极易在“黑暗”中迷失方向,在“跳跃式”访问中烦乱不已和在等待中失去耐心。
  - (4) Web 只有很小的一部分是相关或有用的。据说 99% 的 Web 信息相对于 99% 的用户是无用的,虽然这看起来不是很明显,但每个人只关心很小一部分 Web 信息确是事实。
- 由于 Web 数据的复杂性和动态性,难以搜索、发现和利用 Web 中蕴藏的大量知识,因此 Web 挖掘是知识发现领域的关键问题之一。



## 9.1 概述

### 9.1.1 定义

Web挖掘从数据挖掘发展而来,但 Web挖掘比传统的数据挖掘复杂,涉及数据挖掘、计算机语言学和信息科学等多个领域。研究者从不同的角度出发,对 Web挖掘的定义有所不同。

各种文献中,常见的 Web挖掘定义如下:

#### (1) 描述性的定义

Web挖掘是指使用数据挖掘技术在 WWW 数据中发现潜在的、有用的模式或信息。Web挖掘是一项综合技术,覆盖了多个研究领域,包括 Web 技术、数据库、数据挖掘、计算机语言学、信息获取、统计学以及人工智能等。

#### (2) 抽象化的定义

一般地,Web挖掘是指从大量 Web 集合  $C$  中发现隐含的模式  $p$ 。如果将  $C$  看做输入,  $p$  看做输出,则 Web挖掘就是一个从输入到输出的映射,即  $\xi: C \rightarrow p$ 。

#### (3) 概括性的定义

Web挖掘是从与 WWW 相关的资源和行为中抽取感兴趣的、潜在有用的模式和隐含信息。

Web挖掘可在很多方面发挥作用,如搜索引擎、结构挖掘、确定权威页面、Web 文档分类、Web 日志挖掘和智能检索等。

根据对 Web 兴趣的不同,通常 Web挖掘可分为 Web 内容挖掘(Web content mining)、Web 结构挖掘(Web structure mining)和 Web 使用挖掘(Web usage mining)三类,如图 9.1 所示。

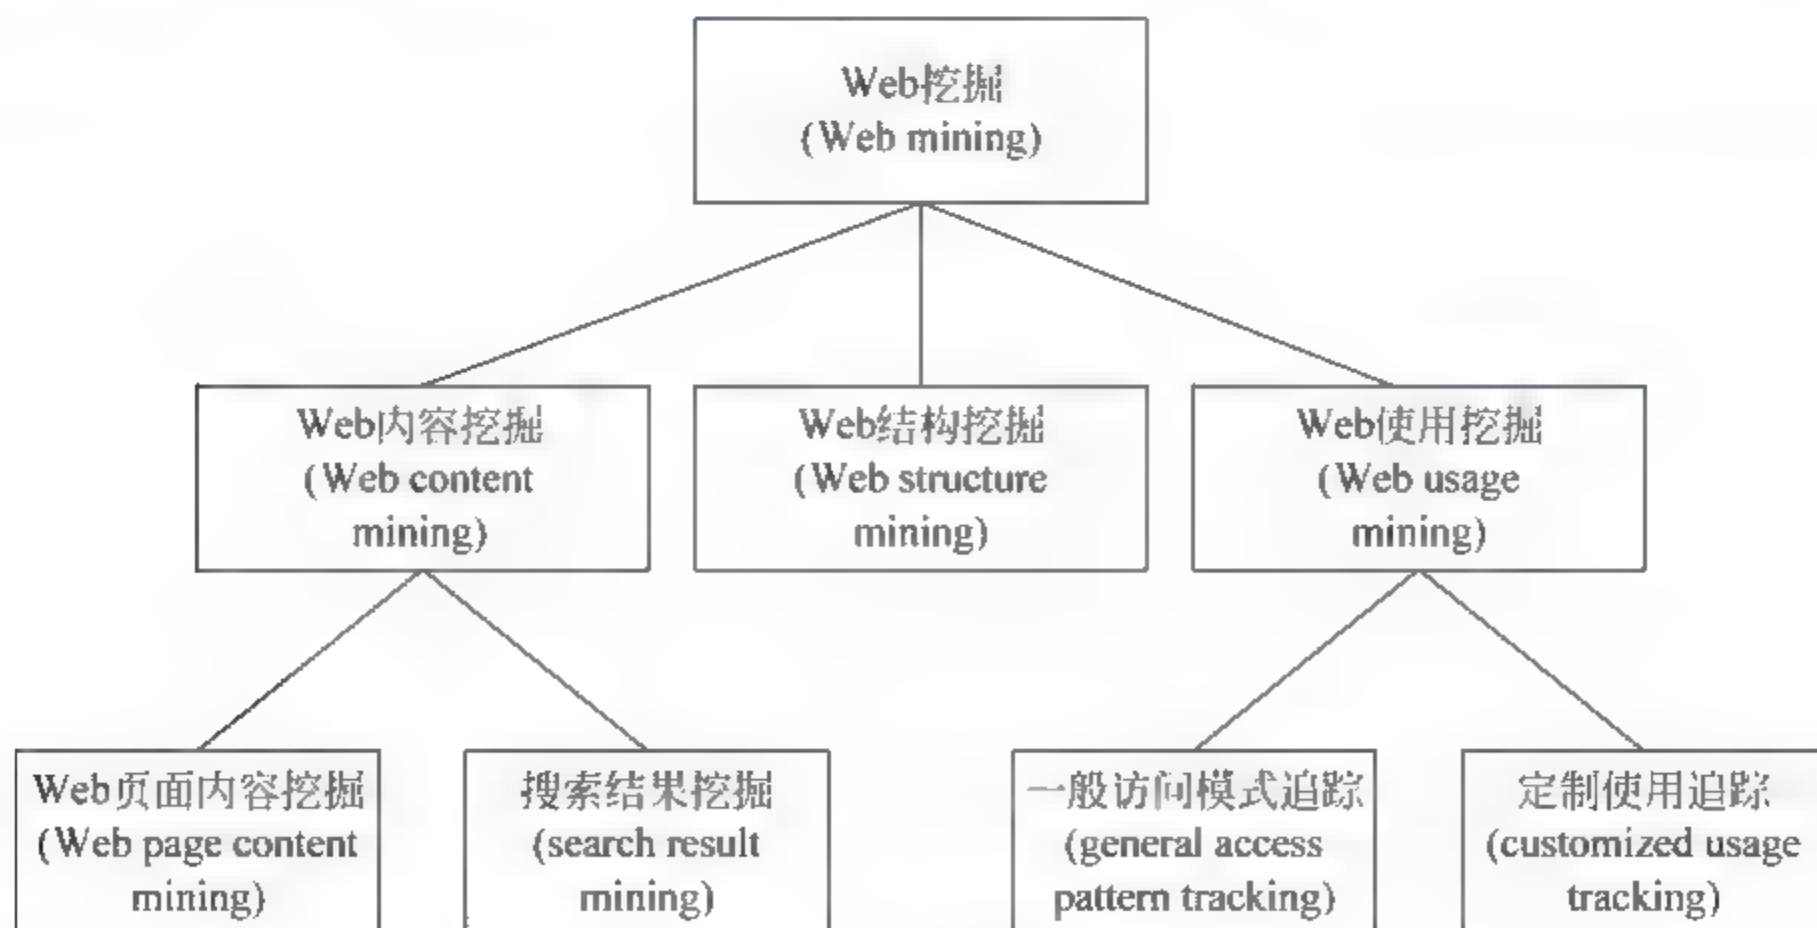


图 9.1 Web挖掘的分类

#### 1. Web 内容挖掘

Web 内容挖掘是指从 Web 内容中发现有用信息,Web 信息五花八门,如政府信息服



务、数字图书馆、电子商务数据以及其他各种通过 Web 访问的数据库。Web 内容挖掘对象包括文本、图像、音频、视频、多媒体和其他各种类型的数据,其中针对非结构化文本的 Web 挖掘被归类到基于文本的知识发现,也称文本数据挖掘或文本挖掘。最近,Web 多媒体数据挖掘成为一个热点。

一般地,Web 内容挖掘可以从两种不同的角度展开。从资源查找(Information Retrieval,IR)的角度看,Web 内容挖掘的任务是从用户的角度出发,提高信息质量和帮助用户过滤信息;从数据库的角度看,Web 内容挖掘的主要任务是对 Web 数据进行集成、建模,以支持复杂的 Web 查询。

#### 1) 从资源查找的角度挖掘非结构化文档

非结构化文档主要指 Web 上的自由文本,包括小说、新闻等。这方面的研究相对比较多,大部分研究都是建立在词汇袋(bag of words)或向量表示(vector representation)的基础上,这种方法将单个词汇看成文档集合中的属性,只从统计的角度将词汇孤立地看待而忽略该词汇出现的位置和上下文环境。属性可以是布尔型,即词汇是否在文档中出现;也可以是频度,即词汇在文档中的出现频率。词汇袋方法的一个弊端是自由文本中的词汇量非常大,难以处理。为解决上述问题,可采用信息增益、交叉熵和差异比等方法减少属性。另外,一种比较有意义的方法是潜在语义索引(latent semantic indexing),通过分析不同文档中相同主题的共享词汇,找到其共同的词根,利用这个公共词根代替所有词汇,以此减少维空间,例如 informing、information、informer 和 informed 可以用它们的词根 inform 表示,这样可以减少属性集合的规模。

其他的属性表示法还包括词汇在文档中的出现位置、层次关系、使用短语,使用术语和命名实体等。目前还没有研究表明一种表示方法明显优于另一种。

#### 2) 从资源查找的角度挖掘半结构化文档

与非结构化文档相比,Web 半结构化文档挖掘是指对加入了 HTML、超链接等附加结构的信息进行挖掘,其应用包括超链接文本的分类、聚类、发现文档之间的关系以及提出半结构化文档中的模式和规则等。

#### 3) 从数据库的角度挖掘非结构化文档

数据库技术应用于 Web 挖掘主要是为了解决 Web 信息的管理和查询问题。这些问题可以分为三类:Web 信息的建模和查询;信息抽取与集成;Web 站点构建和重构。

从数据库的观点进行 Web 内容挖掘主要是建立 Web 数据模型并加以集成,以支持复杂查询,而不只是简单的基于关键词的搜索。这要通过找到 Web 文档的模式、建立 Web 数据仓库或 Web 知识库或虚拟数据库实现。

主要利用 OEM(Object Exchange Model,对象交换模型)将半结构化数据表示成标识图。OEM 的每个对象都有对象标识(OID)和值,值可以是原子类型,如整型、字符串、gif 和 html 等,也可以是一个复合类型,以对象引用集合的形式表示。由于 Web 数量非常庞大,从应用的角度考虑,很多研究只处理半结构化数据的一个常用子集。一些有意义的应用是建立多层数据库,每一层是其下面层次的概化,这样可以进行一些特殊的查询和信息处理。由于数据的表示方法较特殊,其中包含了关系层次和图形化的数据,所以大部分建立在扁平数据集之上的数据挖掘方法不能直接使用,目前已经开展针对多层数据库挖掘算法的研究。



## 2. Web 结构挖掘

Web 结构挖掘的对象是 Web 本身的超链接,即对 Web 文档结构的挖掘。对于给定的 Web 文档集合,应该能够通过算法发现它们之间链接情况的有用信息,文档之间的超链接反映包含、引用或者从属关系,引用文档对被引用文档的说明往往更客观、更概括和更准确。

Web 结构挖掘在一定程度上得益于社会网络和引用分析的研究。把 Web 之间的关系分为 incoming 和 outgoing 连接,运用引用分析方法找到同一网站内部以及不同网站之间的链接关系。在 Web 结构挖掘领域最著名的算法是 HITS 和 PageRank 算法,其共同点是通过计算 Web 之间超链接的质量,从而得到页面权重。著名的 Google 搜索引擎采用了该类算法。此外,Web 结构挖掘的另一个尝试是在 Web 数据仓库环境下,通过检查同一台服务器上的本地连接衡量 Web 结构,挖掘 Web 站点的完全性,在不同的 Web 数据仓库中检查副本以帮助定位镜像站点,通过发现针对某一特定领域的超链接的层次属性探索信息流动如何影响 Web 站点的设计。

## 3. Web 使用挖掘

即 Web 使用记录挖掘,在新兴的电子商务领域具有重要意义。它通过挖掘相关的 Web 日志,发现用户访问 Web 页面的模式,通过分析日志的规律,可以识别用户的忠诚度、喜好和满意度,可以发现潜在用户,增强站点的服务竞争力。除了服务器日志外,还包括代理服务器日志、浏览器端日志、注册信息、用户会话信息、交易信息、Cookie 中的信息、用户查询和鼠标点击流等一切用户与站点之间可能的交互记录。Web 使用记录的数据量非常巨大,而且数据类型也相当丰富。

根据对数据源的处理方法不同,Web 使用挖掘可以分为两类,其一是将 Web 使用记录转换并导入传统的关系表,再使用数据挖掘算法对关系表数据进行常规挖掘;其二是将 Web 使用记录直接预处理再进行挖掘。Web 使用挖掘的一个有趣问题是在多个用户使用同一个代理服务器环境下如何标识某个用户,如何识别属于该用户的会话和使用记录,这个问题看起来不大,但却在很大程度上影响着挖掘质量。通常经典的数据挖掘算法都可以直接用于 Web 使用挖掘。但是,为了提高挖掘质量,可采用改进算法,如复合关联规则算法、改进的序列发现算法等。

Web 使用挖掘的应用主要体现在:

### 1) 个性挖掘

针对单个用户的使用记录对该用户进行建模,结合该用户基本信息分析其使用习惯、个人喜好,目的是在电子商务环境下为该用户提供与众不同的个性化服务。

### 2) 系统改进

Web 服务(数据库、网络等)的性能和其他的服务质量是衡量用户满意度的关键指标,Web 使用挖掘可以通过用户的拥塞记录发现站点的性能瓶颈,提示站点管理者改进 Web 缓存策略、网络传输策略、流量负载均衡机制和数据分布策略等。此外,还可以通过分析网络的非法入侵数据发现系统弱点,提高站点安全性,这在电子商务环境下尤为重要。

### 3) 站点修改

站点的结构和内容是吸引用户的关键。Web 使用挖掘通过挖掘用户的行为记录和反馈信息为站点设计者提供改进依据,例如页面链接如何组织、哪些页面能够直接访问等。

### 4) 智能商务

用户怎样使用 Web 站点的信息无疑是电子商务销售商关心的重点,用户一次访问的周



期可分为吸引、驻留、购买和离开四个阶段。Web 使用挖掘可以通过分析用户点击流等 Web 日志挖掘用户行为的动机,帮助销售商制定合理的营销策略。

#### 5) Web 特征描述

通过用户对站点的访问情况统计各个用户的 Web 交互情况,描述用户的访问特征。

综上所述,目前 Web 挖掘存在的不足主要体现在:

- Web 内容挖掘、Web 结构挖掘和 Web 使用挖掘相互独立,没有互相利用有机结合。例如 Web 内容挖掘算法没有充分利用 Web 文档中的结构信息和超链接信息。
- Web 内容挖掘几乎没有利用语义信息。目前的 Web 文档内容挖掘大都是基于信息提取,而没有在获取 Web 文档的语义信息基础上建立挖掘的理论和算法,这使得挖掘结果的精度较差,质量不够理想。
- Web 挖掘算法尚不能有效处理海量数据。这也是传统数据挖掘面临的难题之一。

### 9.1.2 自然语言理解

随着社会的日益信息化,人们越来越强烈地希望用自然语言同计算机交流,建立起一种人与机器之间的密切而友好的关系,使之能进行高级的信息传递与认知活动。自然语言理解是计算机科学中一个引人入胜、富有挑战性的课题。从计算机科学特别是从人工智能的观点看,自然语言理解的任务是建立一种计算机模型,它能够给出像人那样理解、分析并回答自然语言(即人们日常使用的各种通俗语言)的结果。自然语言处理就是研究如何能让计算机理解并生成人们日常所使用的语言(如汉语、英语等),让计算机懂得自然语言的含义,并对人给计算机提出的问题,通过对话的方式,用自然语言进行回答。自然语言理解系统可以用作专家系统、知识工程、情报检索、办公自动化的自然语言人机接口,具有重要的实用价值。

#### 1. 自然语言理解的发展与演变

由于对自然语言理解的需求,因此对自然语言处理的研究在电子计算机问世之初就开始了。20 世纪 40 年代末期就有学者提出用计算机进行自然语言翻译的构想,并于 50 年代初开展了机器翻译试验。第一代翻译系统以词汇转换为主,很少进行句法分析,还不能称作“理解”。

到了 20 世纪 60 年代,乔姆斯基的转换生成语法得到广泛的认可,对句子的分析就是利用短语结构规则自顶向下或自底向上地生成句法树,从而得到句子的句法结构。转换生成语法把机器翻译带入句法分析的时代,也使得对自然语言的处理提升到新的水平。由于认识到生成语法缺少表示语义知识的手段,不利于自然语言理解,在 70 年代随着认知科学的兴盛,学者们纷纷从语义的角度出发,提出语义理论,在自然语言处理中大量引进语义、语境以及语用的分析技术。20 世纪 60 年代末期,M. R. Quillian 提出了语义网络理论,用于描述概念之间的关系;C. J. Fillmore 提出了格语法,用语义格和深层格框描述句义;1973 年,Roger Schank 提出了概念从属(Conceptual Dependency, CD)理论,描述句义和言语义;1975 年,Minsky 提出了框架理论,用于描述事物或概念状态。这些理论经过发展,逐渐开始趋于相互结合。

到 20 世纪 80 年代一批新的语法理论脱颖而出,具有代表性的包括词汇功能语法



(Lexical Function Grammar, LFG)、功能合一语法(Functional Unification Grammar, FUG)、广义短语结构语法(Generalized Phrase Structure Grammar, GPSG)等。虽然,这些基于规则的分析方法基本上解决了单个句子的分析技术,但是还很难覆盖全面的语言现象,特别是对于整个段落或篇章的理解还无从下手。

20世纪90年代,在自然语言处理领域中,出现了基于语料库的方法,对大规模真实文本进行处理。这些方法包括统计、基于实例的方法等。通过词法、句法、语义等多层次的加工从未经处理的生语料中获取各种语言知识、情景知识和语境知识等,然后利用这些知识对语言进行分析理解。因此基于知识的方法成为主流发展趋势。从整个自然语言理解的发展历程来看,自然语言理解经历了从单纯依靠语法规则到语义分析与句法分析相结合,到最后利用知识消除歧义的过程。

语料库是大量文本的集合,计算机出现后,语料可以被方便地存储起来,利用计算机查找也很容易。随着电子出版物的出现,语料采集也不再困难。最早于20世纪60年代编制的Brown和LOB两个计算机语料库,分别具有100万词次的规模。进入90年代可列举出的语料库有几十个之多,如DCI、ECI、ICAME、BNC、LDC和CLR等,规模最大达到 $10^9$ 数量级。

对语料库的研究分为三个方面:工具软件的开发、语料库的标注和基于语料库的语言分析方法。采集后未经处理的生语料不能直接提供有关语言的各种知识,只有通过词法、句法、语义等多层次的加工才能使知识获取成为可能。加工的方式就是在语料中标注各种记号,标注的内容包括每个词的词性、语义项、短语结构、句型和句间关系等。随着标注程度的加深语料库逐渐熟化,成为一个分布的、统计意义上的知识源。利用这个知识源可以进行许多语言分析工作,例如根据从已标注语料中总结出的频度规律可以给新文本逐词标注词性,划分句子成分等。

语料库提供的知识是用统计强度表示的,而不是确定性的,随着规模的扩大,旨在覆盖全面的语言现象。但是对于语言中基本的确定性的规则仍然用统计强度的大小去判断,这与人们的常识相违背。这种“经验主义”研究中的不足要靠理性的方法弥补。两类方法的融合也正是当前自然语言处理发展的趋势。

自然语言理解系统的发展可以分为第一代系统和第二代系统两个阶段。第一代系统建立在对词类和词序分析的基础之上,分析中经常使用统计方法;第二代系统则开始引入语义甚至语用和语境的因素,几乎完全抛开了统计技术。

第一代自然语言理解系统又可分为四种类型,即:

#### 1) 特殊格式系统

早期的自然语言理解系统大多数是特殊格式系统,根据人机对话内容的特点,采用特殊的格式进行人机对话。1963年,林德赛(R. Lindsay)用IPL V(Information Processing Language V)表处理语言设计的SAD-SAM系统,就采用了特殊格式进行关于亲属关系方面的人机对话,系统内建立了一个关于亲属关系的数据库,可接收关于亲属关系方面问题的英语句子提问,并用英语作出回答;1968年,波布洛(D. Bobrow)在美国麻省理工学院设计了STUDENT系统,这个系统把高中代数应用题中的英语句子归纳为一些基本模式,由计算机来理解这些应用题中的英语句子,列出方程求解并给出答案。20世纪60年代初期,格林(B. Green)在美国林肯实验室建立了BASEBALL系统,也使用IPL V表处理语言,系统



的数据库中存储了关于美国 1959 年联邦棒球赛得分记录的数据,可回答有关棒球赛的一些问题。该系统的句法分析能力较差,输入句子十分简单,没有连接词,也没有比较级形式的形容词和副词,主要靠一部机器词典进行单词的识别,使用了 14 个词类范畴,所有的问题都采用一种特殊的规范表达式回答。

## 2) 以文本为基础的系统

特殊格式系统中格式的限制,带来了诸多不便。因为就一个专门领域而言,最方便的还是使用不受特殊格式结构限制的系统进行人机对话,因此后来出现了以文本为基础的系统,1966 年西蒙(R. F. Simmons)、布尔格(J. F. Burger)和龙格(R. E. Long)设计的 PROSYNTHESIS-I 系统,就是以文本信息的存储和检索方式工作的。

## 3) 有限逻辑系统

有限逻辑系统进一步改进了以文本为基础的系统。在这种系统中,自然语言的句子以某种更加形式化的记号替代,这些记号自成一个有限逻辑系统,可以进行某些推理。1968 年,拉菲尔(B. Raphael)在美国麻省理工学院用 LISP 语言建立了 SIR 系统,针对英语提出了 24 个匹配模式,把输入的英语句子与这些模式相匹配,从而识别输入句子的结构,在从存储知识的数据库到回答问题的过程中,可以处理人们对话中常用的一些概念,如集合的包含关系、空间关系等,可进行简单逻辑推理,并且机器能在对话中进行学习,记住已学过的知识,从事一些初步的智能活动。1965 年,斯莱格勒(J. R. Slagle)建立了 DEDUCOM 系统,可在情报检索中进行演绎推理。1966 年,桑普逊(F. B. Thompson)建立了 DEACON 系统,通过英语管理一个虚构的军用数据库,设计中使用了环结构和近似英语的概念进行推理。1968 年,凯罗格(C. Kellog)在 IBM360/67 计算机上,建立了 CONVERSE 系统,它能根据美国 120 个城市的 1000 个事实的文件进行推理。

## 4) 一般演绎系统

一般演绎系统使用某些标准数学符号(如谓词演算符号)表达信息。逻辑学家们在定理证明工作上取得的全部成就,就可以用来作为建立有效的演绎系统的根据,从而能够把任何一个问题用定理证明的方式表达出来,并实际地演绎出所需要的信息,用自然语言做出回答。一般演绎系统可以表达那些在有限逻辑系统中不容易表达出来的复杂信息,进一步提高了自然语言理解系统的能力。1968 年至 1969 年,格林和拉菲尔建立的 QA2 和 QA3 系统,采用谓词演算的方式和格式化的数据进行演绎推理,解答问题,并用英语作出回答,这是一般演绎系统的典型代表。

1970 年以来,出现了第二代自然语言理解系统,这些系统绝大多数是程序演绎系统,大量地进行语义、语境乃至语用的分析。其中比较有名的是 LUNAR、SHRDLU、MARGIE、SAM 和 PAM 等系统。

LUNAR 系统是伍兹(W. Woods)于 1972 年设计的一个自然语言情报检索系统。该系统采用形式提问语言(formal query language)表示所提问的语义,从而对提问的句子作出语义解释,最后把形式提问语言用于数据库,产生对问题的回答。

SHRDLU 系统是维诺格拉德(T. Winograd)于 1972 年在美国麻省理工学院建立的一个用自然语言指挥机器人动作的系统。该系统把句法分析、语义分析和逻辑推理结合起来,大大地增强了系统在语言分析方面的功能。该系统对话的对象是一个具有简单的“手”和“眼”的玩具机器人,它可以操作放在桌子上的具有不同颜色、尺寸和形状的玩具积木,如立



方体、棱锥体和盒子等,机器人能够根据操作人员的命令把这些积木捡起来,移动它们去搭成新的积木结构。在人机对话过程中,操作人员能获得发送给机器人的各种视觉反馈,实时地观察机器人理解语言、执行命令的情况。在电视屏幕上还可以显示出这个机器人的模拟形象以及它同 一个真正的活人在电传机上自由地用英语对话的生动情景。

MARGIE 系统是香克(R. Schank)于 1975 年在美国斯坦福大学人工智能实验室研制出来的。该系统的目的在于提供一个自然语言理解的直观模型。系统首先把英语句子转换为概念依存表达式,然后根据系统中有关信息进行推理,从概念依存表达式中推演出大量的事实。由于人们在理解句子时,总要牵涉到比句子的外部表达多得多的内容,因此,该系统的推理有 16 种类型,如原因、效应、说明和功能等。最后,把推理的结果转换成英语输出。

SAM 系统是阿贝尔森(R. Abelson)于 1975 年在美国耶鲁大学建立的。该系统采用脚本(Script)理解自然语言写的故事。所谓脚本,就是用来描述人们活动(如吃饭、看病)的一种标准化的事件系列。

PAM 系统是威林斯基(R. Wilensky)于 1978 年在美国耶鲁大学建立的另一个理解故事的系统。PAM 系统也能解释故事情节,回答问题,进行推论,做出摘要。它除了“脚本”中的事件序列之外,还提出了计划(plan)作为理解故事的基础。所谓计划就是故事中的人物为实现其目的所要采取的手段。如果要通过“计划”理解故事,就要找出人物的目的以及为完成这个目的所采取的行动。系统中设有一个“计划库”(plan box),存储着有关各种目的的信息以及各种手段的信息。这样,在理解故事时只要找到故事中有关情节与计划库中存储的信息相重合的部分,就可以理解到这个故事的目的是什么。当一个一个的故事情节与脚本匹配出现障碍时,由于“计划库”中可提供关于一般目的的信息,就不致造成故事理解的失败。例如,营救一个被暴徒劫持的人质,在“营救”这个总目的项下列出若干个子目的,包括到达暴徒的巢穴以及杀死暴徒的各种方法,就可以预期下一步的行为。同时能根据主题来推论目的。例如输入故事:“约翰爱玛丽;玛丽被暴徒抢走了。”PAM 系统即可预期约翰要采取行动营救玛丽。故事中虽然没有这样的内容,但是,根据计划库中的“爱情主题”,可以推出“约翰要采取行动营救玛丽”的情节。

上述系统都是书面的自然语言理解系统,输入和输出都是用书面文字。口头的自然语言理解系统,还牵涉到语音识别、语音合成等复杂技术,显然是更加困难的,口头自然语言理解系统的研究近年来也有一定进展。

## 2. 现代汉语的研究现状

汉语研究基本上都是从概率统计向着汉语的语义研究方向发展。语义是汉语理解的一条蹊径,以词义为基础与句法规则结合,以句子为突破口。国内主要针对汉语信息处理的研究项目主要有以下三个流派。

(1) 以传统计算语言学为基本理论,从词素分析入手,进而研究词 短语(词组) 语段 句子。概括地说,传统计算语言学的种种理论和方法,都以语料统计为基础,因此还需要结合语言规则,例如借鉴了西方计算语言学的众多理论和方法如短语结构语法、扩充转移网络、从属关系语法和配价语法等。

(2) 概念层次网络(Hierarchical Network of Concepts, HNC)理论。黄曾阳提出的 HNC 理论认为,自然语言理解的关键是描述人的语言感知过程的适当模式,试图建立一种模拟大脑语言认知过程的自然语言的计算机理解处理模式。HNC 把自然语言要表述的知



识划分为概念、语言和常识三个独立的层面,并为此建立不同的知识库,通过建立局部和全局两类联想脉络帮助计算机理解自然语言。

(3) 基于内涵模型论的语义分析,该理论是由陆汝占教授提出的。该理论将汉语表达式抽象成数学表达式,恰当地表示内涵和外延,然后把这些语义表示在计算机内进行处理,即把汉语表达式与计算机数据结构之间直接联结,改变为汉语表达式-抽象数学表示-数据结构三者的间接联结。具体设想是先构造一种句子的逻辑式之间的中介形式“函子”(functor),以表示谓语动词连同支配成分一起构成的语句核心,表现句义的基本要素。函子加上时态、模态算子就可以表示语态,构成句子的基本逻辑含义。

以上对汉语的研究面临着不同的问题。第一种流派较好地处理了汉语的表层语法结构,但是面临着如何集成和如何解决词义、句子的问题;第三种流派,理论设计还较粗略,趋向于把自然语言的表示数学化,虽然这一理论已经解决了一些实用问题,但是对自然语言本身的理解做得不够,要证明它可以适用于整个现代汉语,还需要进一步推敲、实验和细化。

对汉语的处理不仅依赖于语言的表层结构表示,更重要的是语言的深层结构层次的表示。第二种流派 HNC 提出了深层次的语言结构的表示,语言抽象表示的概念化和层次化都适合汉语的研究,但需要建立庞大的知识库,总体地检验和完善其理论和技术的可行性,因此该理论需要长期的实践验证。此外,鲁川对汉语的信息处理,提出了汉语的意合网络,给出了语义的组合知识,但是对于知识的获取涉及甚少。董振东提出的知网(How-Net)建立了一个以揭示概念与概念之间以及概念所具有的属性之间的关系为基本内容的常识知识库,但是对概念的描述停留在词汇层面上,没有足够的知识适合于计算机推理。俞士汉等初步建成了“现代汉语语法电子词典”,提出了现代汉语词语分类体系,但只服务于语言信息处理。

### 3. 自然语言理解的相关理论

#### 1) 国外研究现状

国外关于自然语言理解方面的研究起步较早,一些卓有成就的语言学家、逻辑学家和心理学家都在自然语言理解的语法、句法及语义分析方面提出了一些较为系统的理论和方法。下面介绍一些比较有影响的理论。

#### (1) 形式语言

1957 年美国语言学家 Chomsky 提出了形式语言理论,将语言看成是一个抽象的符号系统,定义为按一定的规律构成的句子或符号串的有限的或无限的集合,记为  $L$ ,一种语言的文法  $G$  是一种格式,用来说明什么句子在该语言中是合法的,并指明把词组合成短语和子句的规则,即  $G$  定义为:

$$G=(T,N,S,P)$$

其中, $T$  是终结符的集合,终结符是指被定义的那个语言的词(或符号); $N$  是非终结符的集合,这些符号不能出现在最终生成的句子中,是专门用来描述语法的; $S$  是起始符,它是集合  $N$  中的一个成员; $P$  是一个产生式规则集。

以英语中一个很小的子集为例,具有如下的文法:

$$\begin{aligned} G &= (T, N, S, P) \\ T &= \{\text{the, dog, cat, runs, ...}\} \\ N &= \{S, NP, VP\} \\ S &= \{S\} \end{aligned}$$

产生式规则集  $P$  的规则:



$S = NP + VP$ ;  $N = \text{dog}$ ;  $NP = \text{the} + N$ ;  $N = \text{cat}$ ;  $VP = \text{runs}$

根据这一简单文法,能生成以下两个英语句子:

The cat runs.

The dog runs.

Chomsky 希望,如果能找到一种描述英语的形式文法,人们就可以根据它使用计算机“理解”英语。但是到目前为止,这一目标仍然没有实现。从自然语言处理的观点来看,形式地定义一种语言的意义在于:如果系统要处理句子的结构是已知的,那么就比较容易写出一种分析算法来对输入语句进行句法分析。

### (2) 转移生成语法

1957 年 Chomsky 曾提出了转换生成语法(Transformational Generative Grammar),将句子的结构分为深层结构和表层结构两个层次,并根据形式文法中所使用的规则集不同将语法分为四种类型:无约束短语结构(0 型语法);上下文有关语法(1 型语法);上下文无关语法(2 型语法);正则语法(3 型语法)。一些表达相同意义的句子尽管表层结构不同,但其深层结构却是相同的。例如:

The car will hit that tree soon.

That tree will be hit by the car soon.

转换生成语法的原理是通过上下文无关语法生成句子的深层结构(形式语言),然后应用转换规则再将深层结构转换为表层结构。如果要进行句子分析,则首先要逆向应用转换规则将表层结构转换为深层结构,之后再应用上下文无关语法进行分析。

Chomsky 在语法中完全抛开了语义、语用和语境方面的知识,只局限于一种形式化的机制,因此很难完全确切地描述自然语言。

### (3) 扩展转移网络

1970 年美国的 Woods 根据 Chomsky 创建的转换生成语法,设计了扩展转移网络(Augmented Transition Network, ATN)。

转移网络是自然语言中常用的自动机,每个转移网络由一个状态集和一个标号集组成,其构成方法可以表示为:

$$\text{状态} \times \text{标号} = \text{状态}$$

其含义是给定当前状态和当前标号后,可以求得下一步状态。在识别语言时,状态是指当前的句子分析到了哪一步,标号指的是当前面临的语法成分是什么。

设有  $Q_0, Q_1, Q_2$  和  $Q_3$  四个状态。 $Q_0$  表示语句分析开始; $Q_1$  表示主语分析完毕; $Q_2$  表示谓语分析完毕; $Q_3$  表示全句分析完毕。又有 NP 和 VP 两个标号。图 9.2 所示是一个简单的转移网络,该网络可用来分析许多简单语句,例如:



图 9.2 一个简单的转移网络

Mary finished the job.

Tom plays basketball.

自然语言中的句子可以是非常复杂的,如果要考虑到句子结构的各种可能性,则转移网络也将变得非常复杂。为了降低复杂度,人们研究如何把转移网络模块化,并尽可能分成层

次结构,为此提出了递归转移网络。在递归转移网络中,标号可以是简单的词类,也可以是另一个递归转移网络的名字。

但是递归转移网络仍存在严重的不足,主要问题是在分析完一个句子之后,它只能给出关于该句子是否符合语法的信息,而不能回答有关该句子的语法结构这类问题。原因在于分析时未能把所得到的信息记录下来。为此,Woods 把递归转移网络加以扩充,成为 ATN。ATN 用一组寄存器保存语法分析信息。它每走一步都要测试一下当前情况并根据测试结果决定做什么动作。最后把各寄存器中的信息综合起来,得到分析句子的语法结构。

ATN 的弱点在于其对句法的过分依赖,限制了对语言的处理能力,在某些情况下效率很低。

#### (4) 格语法

20 世纪 60 年代末,美国语言学家 Fillmore 提出了一种新的理论——格语法(case grammar)。格语法将自然语言理解中的语法和语义分析结合起来,它的语法规则是用于描述语法规律而不是语义规律的,但规律所产生的最终结构不是严格表示语法结构而是描述语义关系。

按照 Fillmore 的观点,一个句子可以由情态和命题两部分组成。如果用 S 表示句子(sentence),用 M 表示情态(modality),用 P 表示命题(proposition)则:

$$S=M+P$$

命题 P 是动词与其相关的格。如果用 V 表示动词,用  $C_1, C_2, \dots, C_n$  表示各种格,则可写为:

$$P=V+C_1+C_2+\dots+C_n$$

而每一个格又可以表示为一个格标(记为 K)再加上一个名词短语。若用  $C_i$  表示格,则可写为:

$$C_i=K+NP$$

其中 K 可以是介词,也可以为空。

情态 M 是一系列从整体上描述句子各方面的术语,主要是指时态、体、形式、方式和时间等,可定义为:

$$M= \text{Tense, Aspect, Form, Mood, Essence, Modal, Manner, Time}$$

其中

Tense: present, past, future

Aspect: perfect, imperfect

Form: simple, emphatic, progressive

Mood: declarative, interrogative, imperative

Essence: positive, negative, indeterminate

Modal: may, can, must

Manner: adverbial

Time: adverbial

#### (5) 概念从属理论

1973 年美国的 Schank 提出了概念从属(Conceptual Dependency Theory, CD 理论)理论,这种理论与格语法有相似之处,如句子意义的表达以行为(action)为中心,并包括一些与其相关的句子其他词的格。但两者之间也有明显的区别,CD 理论中句子的行为不是由



动词表示,而是由原语行为集表示,其中每一个原语是包含动词意义的概念。换言之,行为是由动词的概念表示,而不是由动词本身表示。

让我们看两个例句:

John gave the vase to Mary.

Mary received the vase from John.

以上两句尽管侧重点不同、所用的动词不同,但基本概念是相同的,都是关于所有权的转移。但在格语法中,这两个句子的内部存储将采用完全不同的形式。CD 理论指出物体所有权转移是原语行动 ATRANS。因此,上述第一句可表示为:

EVENT1

ACTOR: John

ACTION: ATRANS

OBJECT: the vase

DIRECTION: FROM: John TO: Mary

第二句可表示为:

EVENT2

ACTOR: Mary

ACTION: ATRANS

OBJECT: the vase

DIRECTION: FROM: John TO: Mary

EVENT1 和 EVENT2 分别表示了两句的意义,两者的差异仅在于动作的完成者。

由于运用 CD 理论理解自然语言时,大量使用到语义知识,使得对纯粹语法分析有歧义性的句子也能赋以唯一的解释。但另一方面,要很好地完成分析工作又需要庞大的语义知识库。

#### (6) 境况语义学

1983 年美国的 Barwise 和 Perry 建立了境况语义学(situation semantics)。境况语义学是一种语义和语用相结合的语义分析理论。

例如: Tom saw a girl with a telescope.

我们既可以理解成“汤姆用一个望远镜看一个姑娘”,也可以理解成“汤姆看到一个拿着一个望远镜的姑娘”。要对这句话作出正确的判断,只有根据上下文信息和特定的语言环境。

境况语义学的任务,就是要从语言环境中获取在语法、语义分析中无法得到的信息,更好地完成自然语言理解。

#### (7) 语料库语言学

近年来,在国际上掀起了语料库语言学(Corpus Linguistics)的研究热潮。语料库语言学研究机器可读的自然语言文本的采集、存储、检索、统计、语法标注、句法 语义分析以及具有上述功能的语料库在语言定量分析、词(字)典编撰、作品风格分析、自然语言理解和机器翻译等领域的应用。

#### 2) 国内研究现状

HNC 理论是关于自然语言理解的一个理论体系。它以概念化、层次化和网络化的语



义表达为基础,所以称之为概念层次网络理论。HNC 理论把人脑认知结构分为局部和全局两类联想脉络,认为对联想脉络的表达是语言深层(即语言的语义层面)的根本问题。

HNC 理论的中心目标是建立自然语言的表示和处理模式,使计算机能够模拟人脑的语言感知功能。该理论使自然语言理解获得了突破性的进展,它所蕴涵的精深丰富的思想对人工智能、语言学、计算机科学和认知科学等都具有重要的理论和应用价值,对中文信息处理和汉语研究尤其具有实际意义。

HNC 理论完全摆脱了现有这套语法学的束缚,而从语言的深层入手,以语义表达为基础,为汉语理解开辟了一条新路。HNC 理论提出了可供工程实现的完整的自然语言理解的理论框架,它是一个面向整个自然语言理解的强大而完备的语义描述体系,包括语句处理、句群处理、篇章处理、短时记忆向长时记忆扩展处理、文本自动学习处理。HNC 理论的出发点就是运用两类联想脉络帮助计算机理解自然语言。自然语言的词汇是用来表达概念的,因此 HNC 建立的词汇层面的局部联想脉络体现为一个概念表达体系。概念分为抽象概念与具体概念。HNC 理论的概念表达体系侧重于抽象概念的表达,对具体概念采取挂靠近似表达方法。HNC 理论认为应该从多元性表现和内涵两个方面描述概念。

HNC 利用五元组表达抽象概念的多元性,对抽象概念的内涵采用网络层次符号表示。其网络层次符号包含三大语义网络:基元概念语义网络、基本概念语义网络和逻辑概念语义网络。HNC 的五元组符号和三大语义网络的层次符号组合起来就可完成抽象概念的完整表达,从而为计算机理解自然语言的语义提供了有力手段。

自然语言理解大致可分为机器翻译(Machine Translation, MT)、语义理解及人机会话几个方面。其中机器翻译是利用计算机把一种自然语言转变成另一种自然语言的过程。智能搜索引擎在这一领域的研究将使得用户可以使用母语搜索非母语的网页,并以母语浏览搜索结果。语义理解通过将语言学的研究成果和计算机技术结合在一起,实现对词语在语义层次上的理解。人机会话技术可以为计算机提供下一代的人机交互接口,实现从文字接口、图形接口到自然语言接口的革命,同时在家用电器的人性化设计方面有着广泛的应用前景,其技术内涵主要包括语音识别和语音合成两个核心部分。

在语义理解的整个过程中,智能分词技术是最初的一个环节,它将组成语句的核心词提炼出来供语义分析模块使用。在分词过程中,如何能够恰当地提供足够的词供分析程序处理,并且过滤掉冗余信息,这是后期语义分析的质量和速度的重要前提。尤里卡的智能分词避免了传统分词技术在拆分时产生的歧义组合。从而为语义理解的处理提供了良好的原始素材。同时,在分词过程中,知识库当中的同义词会被逐个匹配并同时提交给语义理解模块使用,这样处理过的句子不仅提供了原始的句型,还同时搭载了语句的概念部分。

#### 4. 自然语言理解的关键技术

迄今为止,对自然语言理解尚无统一和权威的定义。按照考虑问题的角度不同而有不同的解释。从微观上讲,语言理解是指从自然语言到机器(计算机系统)内部之间的一种映射;从宏观上看,自然语言理解是指机器能够执行人类所期望的某些语言功能。这些功能包括:

- (1) 回答有关提问;
- (2) 提取材料摘要;



(3) 不同词语叙述;

(4) 不同语言翻译。

然而,自然语言理解却是一项十分艰难的任务。即使建立一个只能理解片言断语的计算机系统,也是很不容易的。这中间有大量极为复杂的编码和解码问题。一个能够理解自然语言的计算机系统就像一个人那样需要上下文知识以及根据这些知识和信息进行推理的过程。自然语言不仅存在语义、语法和语音问题,而且还存在模糊性等问题。具体地,自然语言理解的困难是由以下三个因素引起的,即:

(1) 目标表示的复杂性;

(2) 映射类型的多样性;

(3) 源表达中各元素间交互程度的差异性。

近些年来,由于以下因素的推动,即:

- 计算机技术的飞速发展。
- 可用的语料库数量的不断增大。
- 经济发展对大量实用处理系统的迫切需要,使语料库语言学的研究得到了迅速的发展。

从20世纪90年代以来历届重要的国际会议,包括COLING、ACL和TMI等,每届都有许多新的研究成果出现。而对汉语语料库语言学的研究,近年来也有许多研究成果,如自动词性标注、自动分词研究、句法功能标注、语义信息标注、汉语音字转换和汉语语音识别等。但总的说来,发展速度并不是很快,规模也不太大。

## 5. 自然语言理解技术的应用

采用自然语言理解技术的智能信息服务创造了电子服务新概念。它首先对提出的问题进行断词和断句,然后根据系统预先设置的语义规则理解整句话的意思,形成相应的查询条件,在现有数据库进行快速而准确查询,给出用户需要的答案或者提示用户进一步输入有关信息。由于自然语言理解技术发展的阶段性,目前还做不到像人一样具有足够智能、通用的智能理解,但是只要划定具体的领域(领域范围可大可小,如天气、体育等简单信息查询,也可以是交友、购物、保健等宽泛的智能聊天或咨询等),性能先进的自然语言理解技术都能量身定做出具有足够实用性的智能信息服务系统,自动理解客户用自然语言发出的相关领域的问题,使网络交流更人性化,信息查询更方便、快速和准确,从而获得高质量的电子服务。

目前,自然语言理解的应用主要涉及以下方面:

### 1) 智能短信服务

短信服务商可根据具体应用领域定制一系列的智能短信业务,如旅游交通、金融证券、交友网聚、智力竞猜等受欢迎的服务,让服务商和用户都抛开厚重的手册和复杂的编码,代之以口语化的自然语言通过短信输入,短信系统能迅速理解用户的意图,提供准确、周到的信息和服务。这样的服务将直接刺激用户使用短信服务的兴趣和频率,并为短信服务商和电信运营商开发更新的、更具吸引力的业务创造良好条件。

### 2) 智能聊天机器人

目前流行于各大网站、各类即时通信软件的聊天机器人还没有应用成熟的智能语言理解技术,仅仅实现了基本、简单的对话交流、信息查询等功能。引入自然语言理解技术,能构建新型智能聊天机器人,通过与用户对话和聊天等生动、灵活的形式,了解用户需求,利用智



能搜索技术采集和分析互联网和知识库的信息内容,进行自动过滤和筛选,并获取有效内容,对相关信息内容进行智能化编辑整理,最终返回给用户;这样,聊天机器人的服务将会更易用和实用,能够实现功能强大而实用的智能聊天、智能游戏、个性化的新闻定制、智能网络搜索、智能电子商务等,给用户以极大的方便和无限的乐趣。

### 3) 智能搜索引擎

普通的搜索引擎引入中文自然语言理解和知识管理技术,构建成新的智能搜索引擎,能提供全新的信息查询服务,创造更综合的增值服务。目前的搜索引擎由于只使用关键词匹配技术,没有引入自然语言理解,每次搜索时只是按照关键词进行匹配,返回大量信息和链接,其中很大部分是垃圾信息或不是用户所需的信息,往往导致用户无所适从。而门户网站或者专业网站虽然对信息进行很好的分类,但是首先要用户记住网址,还要懂得分类的标准,然后逐层点击相应的分类链接,才能获得所需信息。这样的信息分类查询给信息服务商带来很大的工作量,服务成本和进入门槛显著提高,而用户使用起来也不方便,导致用户的流失。基于内容的智能搜索引擎是依靠语义网络、汉语分词、句法分析、处理同义词等自然语言理解技术最大程度地了解用户的信息需求,获得更高的易用性、更准确的范围定位、更智能的搜索结果。

运用先进的自然语言理解技术,智能搜索引擎可以识别并回答用户的问题,使用户摆脱传统搜索引擎基于关键字的束缚,指引用户更有效、更快捷地寻找到所需信息,同时为用户提供相关的、有参考价值的其他内容。由于这些特点,使得智能搜索技术能够在互联网信息检索的各个方面得到广泛应用。它可以为大型综合搜索引擎提供后台支持,使之具有人性化、交互性的特点。它能够方便地实现垂直搜索引擎的专业类别内容搜索;当然也可以为信息门户网站提供方便快捷的站内信息搜索服务。

智能搜索引擎除了在互联网上使用外,也可以支持 WAP 协议而应用到手机上。其实用户往往在逛街、旅游、交通等室外环境、移动状态时更需要随时查询信息。手机是很好的查询工具,但是手机的屏幕小、内存少、带宽窄,不适合接收和保存大量信息,更不可能翻看数以百计千计的信息。传统的基于关键词搜索或者分类信息查询模式都存在一定的缺陷,特别不适合在手机上使用。而基于自然语言理解技术的智能搜索引擎,就能很好地为手机用户提供随时、随地、随心的信息服务。

人们呼唤自然语言,因为它是人机交互的最高境界,是人机交互最自然的方式。有理由相信,在不远的将来任何人、任何时刻、在任何场所和任何设备上,都可以通过自然语言方便地浏览网页,互相传递信息,实现随时随地沟通交流的目标。

## 9.1.3 Web 挖掘过程

与结构化数据相比,Web 数据是异构的、非结构化或半结构化、动态的,并且容易造成混淆,所以很难直接进行 Web 挖掘,必须经过必要的预处理。

典型的 Web 挖掘过程可概括如下:

### 1. Web 资源搜集

旨在获取 Web 信息,值得注意的是有时信息资源不仅限于在线 Web 文档,还包括电子邮件、电子文档、新闻组或者网站日志甚至是通过 Web 形成的交易数据库的数据。



## 2. 预处理

从获取的 Web 资源中剔除无用信息并进行必要的处理,例如从 Web 中自动删除广告链接、多余格式标记、自动识别段落或字段并组织成规整的逻辑形式甚至是关系表。

Web 文档的内容是人类所使用的自然语言,计算机很难理解其语义。这些特殊性使得现有的数据挖掘技术无法直接应用于 Web 挖掘。需要对 Web 文档进行分析,抽取代表其特征的元数据。这些特征可以用结构化的形式保存,作为 Web 文档的中间表示形式。

在对 Web 文档进行特征提取前,需要先进行预处理。对于英文需进行词干化(stemming)处理,中文的情况则不同,因为中文的词与词之间没有固有的间隔符(空格),需要进行分词。所谓分词是在中文文本的各词条间加入分隔符,将中文文本的连续字流形式转化为离散的词流形式。引入分词主要是为后继的处理做准备。自 20 世纪 80 年代初提出自动分词以来,已提出了许多分词方法,目前采用的分词方法主要包括正向、逆向最大匹配法、逐词遍历法、最佳匹配法和词频统计法等,此外还有二次扫描法、邻接约束法等。大致可以归纳为四类:第一类为基于词典的机械分词算法;第二类为基于统计的分词算法;第三类为第一、二类混合的分词算法;第四类为基于知识的分词专家系统。在具体应用中,需要根据具体情况选择不同的分词方法,不同分词方法的正确性很大程度上取决于所构建的词库。一个词库应具有完备性和完全性两个方面。所谓完备性,简单而言是对任意一个字串,总能按词库找到对其进行切分的方法;所谓完全性,则意味着词库应当包含所有的词。建立一个同时满足上述两个要求的词库具有很大难度。而对于某一系统而言,可能只用到其中的一部分,因此在构造词典时需要量力而行,在完备和效率之间折衷。

## 3. 特征抽取

提取 Web 文本中的特征词,并将抽取出的特征词量化以表示 Web 文本信息。通常根据某一特征评估函数计算各个特征的评分值,然后按评分值对这些特征排序,选取若干个评分值最高的作为特征词。特征抽取对 Web 文本内容的过滤和分类、聚类、自动摘要以及用户兴趣模式发现、知识发现等具有重要作用。

## 4. 模式发现

自动地发现模式,Web 挖掘所产生的知识模式,既可以是对各个文档含义的概括,也可以是有关整个文档集合的结构或趋势描述。

## 5. 模式评价

验证、解释上一步骤产生的模式,既可以机器自动完成,也可以与分析人员一起完成。

最后对挖掘出的模式进行质量评价,若评价的结果满足一定的要求,则存储这一知识模式,否则返回到前面的某一步骤,分析改进后进行新一轮的挖掘。

值得注意的是,Web 挖掘作为一个完整的过程,在挖掘之前的信息检索(Information Retrieval, IR)和信息抽取(Information Extraction, IE)相当重要。IR 旨在获取相关的 Web 文档;IE 旨在从 Web 文档中获取所需信息,对文档的结构和所表达的含义感兴趣,其重要任务之一是对 Web 文档进行组织、整理并建立适当索引。

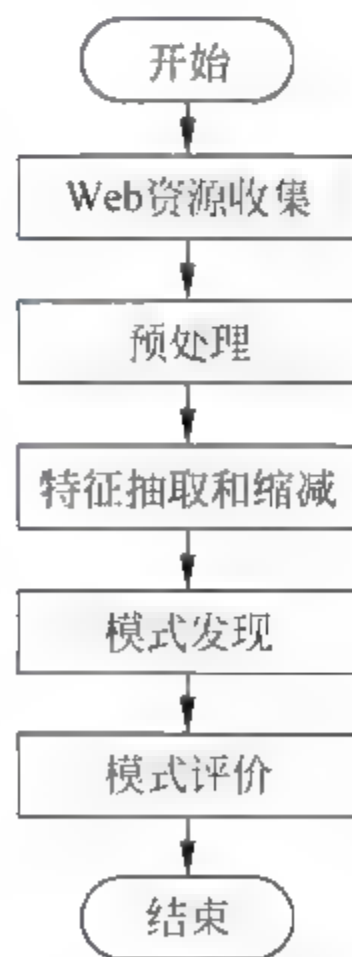


图 9.3 Web 挖掘的一般过程



IR 和 IE 的研究由来已久,随着 Web 技术的发展,基于 Web 的信息检索和抽取获得更多关注。由于 Web 数量庞大且动态变化,以原来手工方式收集早已力不从心,目前采用自动化、半自动化的方法实现 Web 信息检索和抽取。

综上所述,Web 挖掘的一般过程如图 9.3 所示。

## 9.2 Web 文档抽取和表示

Web 挖掘与传统的数据挖掘相比具有许多独特之处。首先,Web 挖掘的对象是大量、异质、分布的 Web。我们认为,以 Web 作为中间件对数据(仓)库进行挖掘,以及对 Web 服务器上的日志、用户信息等挖掘,仍属于传统数据挖掘的范畴;其次,Web 在逻辑上是一个由文档结点和超链接构成的图,因此 Web 挖掘所得到的模式可能是关于 Web 内容的,也可能是关于 Web 结构的。此外,由于 Web 本身是半结构化或非结构化的,且缺乏机器可理解的语义,而数据挖掘的对象局限于数据(仓)库中的结构化数据,并利用关系表等存储结构发现知识,因此有些数据挖掘技术并不适用于 Web 挖掘,即使可用也需要建立在 Web 预处理的基础上。这样,开发新的 Web 挖掘技术,以及对 Web 进行预处理以获取关于 Web 文档的特征表示是 Web 挖掘研究的重点。

### 9.2.1 Web 文档抽取

Web 文档抽取是将半结构化或非结构化 Web 按照一定的需求抽取成结构化数据。例如互联网是一个巨大的资源,Internet 上同一主题的信息通常分散存放在不同网站,表现的形式也各不相同,若能将这些信息收集在一起,采用结构化形式储存是十分有意义的。

实现 Web 文档抽取的方法主要包括两种,一种比较简单的是采用模板,另一种是不依赖网页的网页库结构化抽取。

模板方式是事先对特定的 Web 配置模板,设置需要的信息,可以针对有限多个网站的信息进行精确采集。其优势是简单、精确、技术难度低、便于快速部署;缺点是需要针对每个信息源的网站模板单独设置,在信息来源多样的情况下维护量巨大,所以适合少量信息源的情况,不是搜索引擎级的应用,很难满足用户查全率的要求;网页库结构化抽取方法是采用 Web 结构分析与智能结点分析转换的方法,自动抽取结构化的数据。其优势是可对任意正常的 Web 进行抽取,不用对具体网站事先生成模板,对每个 Web 自动实时地生成抽取规则,完全不需要人工干预,因此抽取准确率高,不是机械地匹配,准确率达到 98% 以上。由于采用页面的智能分析技术,去除了垃圾块,降低分析的压力,使处理速度大大提高,通用性较好,易于维护。一般情况下,非专业人员经过简单培训即可操作;缺点是技术难度大,前期研发成本高、周期长,适合网页库级别结构化数据采集和搜索的高端应用。

### 9.2.2 Web 文档表示

Web 挖掘首要解决 Web 异构数据的集成和查询问题,因此需要一个模型清晰地描述 Web。针对 Web 半结构化的特点,寻找一个半结构化的数据模型是解决问题的关键。除了



定义一个半结构化数据模型外,还需要一种半结构化模型抽取技术,即自动地从现有数据抽取半结构化模型。Web挖掘以半结构化模型和半结构化数据模型抽取为前提。

基于XML的新一代WWW直接面对Web数据,不仅可以很好地兼容原有的Web应用,而且可以更好地实现Web数据的共享和交换。XML可看作一种半结构化的数据模型,可以很容易地将XML文档描述与关系数据库的属性一一对应起来,实施精确地查询与模型抽取。

Web文档表示常用的模型是布尔模型、概率模型和向量空间模型(Vector Space Model,VSM)等。其中,向量空间模型在一般的Web挖掘中最常用。

### 1. 布尔模型

采用布尔表达式对Web文档进行标识。布尔模型在传统的信息检索中有着广泛应用,通过与用户给出的检索式进行逻辑比较检索文档,本质上是一种基于关键词的匹配。在标准的布尔模型中,Web文档表示为 $D(W_{i1}, W_{i2}, \dots, W_{in})$ ,其中 $n$ 为特征项的个数, $W_{ik}$ 的值为0或1,分别表示特征项 $k$ 在文档 $i$ 中是否出现。

### 2. 概率模型

概率模型考虑词与词的相关性,把Web文档集合中的对象分为相关的和无关的。基于概率论,通过对词赋予某一概率值表示其在相关文档和无关文档出现的概率,然后计算文档之间的相关概率,系统依据词概率做出决策。

概率模型有多种形式,常见的是第二概率模型,其基本思想是词的概率一般是重复若干次相关性计算,每重复一次,就由用户对检出文档进行人工判断。然后利用这种反馈信息,根据词在相关文档集合和无关文档集合的分布计算其相关概率。该模型中,词的权值计算见式(9.1):

$$\log \frac{p(1-p)}{p'(1-p')} \quad (9.1)$$

其中, $p$ 和 $p'$ 分别表示某词在相关文档集合和无关文档集合中出现的概率。某一文档的权值(决定其排序的位置)则是它所含标引词的权值之和,因此文档于用户查询相关概率可定义为:

$$S(Q,D) = \sum_{i=1}^n \frac{p_i(1-p_i)}{p'_i(1-p'_i)} \quad (9.2)$$

概率模型的主要优点体现在:

- 采用严格的数学理论为依据实现匹配
- 采用相关反馈原理

主要缺点包括:

- 增加存储和计算的开销
- 参数估计难度较大

### 3. 向量空间模型

向量空间模型于20世纪60年代末由Gerard Salton等提出,它是一个统计模型。该模型以特征项作为Web文档表示的基本单位。在向量空间模型中,Web文档的内容被形式化为多维空间中的一个点,表示为向量的形式,正是因为把Web文档以向量的形式映射到实数域,极大地提高了Web文档的可计算性和可操作性。



**定义 9.1 文档(document)**

泛指一般的文献或文献中的片段(段落、子句组或句子),一般指一篇文章。

**定义 9.2 项(term)**

当文档的内容被简单地看成是其含有的基本语言单位(字、词、词组或短语等)组成的集合时,这些基本的语言单位统称为项,即文档  $D$  可以用项集(term list)表示为  $D(T_1, T_2, \dots, T_n)$ ,其中  $T_k$  是项,且  $1 \leq k \leq n$ 。

**定义 9.3 项的权重(term weight)**

对于含有  $n$  个项的文档  $D(T_1, T_2, \dots, T_n)$ ,项  $T_k$  常被赋予一定的权重  $W_k$ ,表示其在文档中的重要程度,即  $D(T_1, W_1; T_2, W_2; \dots; T_n, W_n)$ 。有时在特征词条确定时,常简记为  $D(W_1, W_2, \dots, W_n)$ 。

**定义 9.4 向量空间模型**

给定一个文档  $D(T_1, W_1; T_2, W_2; \dots; T_n, W_n)$ ,由于项  $T_k$  在文档中既可以重复出现也存在先后次序的关系,分析起来有一定难度。为了简化,可以暂不考虑  $T_k$  在文档中的先后顺序并要求  $T_k$  互异(即没有重复)。这时可以把  $T_1, T_2, \dots, T_n$  看成一个  $n$  维坐标,而  $W_1, W_2, \dots, W_n$  为相应的坐标值,因而  $D(W_1, W_2, \dots, W_n)$  看成是  $n$  维空间中一个向量,称  $D(W_1, W_2, \dots, W_n)$  为文档  $D$  的向量表示。

**定义 9.5 文档特征向量(feature vector)**

VSM 中每一文档都可以用一个向量表示,向量由项(词条)及其权重组成。该向量称为文档的特征向量,特征向量是文档的一个特征表示,在某种意义上可以完全代表文档的特性。

VSM 中,每一文档被映射成多维向量空间中的一个点,从而将文档的表示和匹配问题转化为向量空间中向量的表示和匹配问题。

VSM 模型的不足之处是将 Web 文档表示成向量,作为向量空间的一个点,然而通过计算向量间的距离进行分类时,一般不考虑向量中各个特征间的关系,这使得距离的计算不够准确,从而导致分类精度不高。

## 9.3 特征提取

Web 挖掘中,通常以特征项组成的向量表示 Web 文档。但如果不加以筛选,特征项的数量可能会成千上万,以 Web 挖掘中的 Web 分类为例,对其至少会造成两方面的不利影响。

(1) 许多 Web 挖掘系统不能处理如此高维的特征向量。例如 Bayes 分类器,即使是利用了独立性假设的 Naive Bayes 方法(这一假设在实际中通常是不正确的)面临这样的特征向量,其计算量也非常巨大。

(2) 特征向量中有些词对于 Web 分类的作用非常小,可以说绝大多数词对于 Web 分类是没有什么作用的,特别是考虑到训练文档的个数非常有限。相反,过多的特征项通常会带来负面影响,这是因为特征项越多,利用有限的训练文档估算特征项的概率分布越不准确。

鉴于上述原因,在 Web 分类之前先进行特征提取,不仅能减小 Web 分类的复杂度,而



且对于提高最终的分类精度也会有所帮助。

在自动 Web 文档特征提取的算法中,通常构造一个评价函数,对特征集中的每一特征进行独立的评估,这样每个特征都获得一个评估分(又称为权值),然后对所有的特征按照其权值大小排序,选取预定数目的最佳特征作为结果的特征子集,即作为文档的主题词提出。

特征提取主要用于排除那些被认为无关或关联性不大的特征(如术语),提取可以代表 Web 文档的特征,为后续的 Web 挖掘奠定基础。目前,特征提取方法很多,如词频统计和 TF-IDF(Term Frequency-Inverse Document Frequency)等。

### 1. 词频统计

词频统计算法非常简单,即合并重复出现的特征项,计算文档  $D(T_1, W_1; T_2, W_2; \dots; T_n, W_n)$  中对应项  $T_i$  的权重  $W_i$ ,  $W_i$  为项  $T_i$  在文档  $D$  中出现的次数,并通过设定适当的权重阈值提取文档特征。

### 2. TF-IDF

TF-IDF 是 Salton 和 McGill 在 1983 年针对向量空间信息检索范例(vector space information retrieval paradigm)提出的特征表示方法,其中 TF(Term Frequency)为特征项的文档内频度,即在文档  $D$  中出现特征项  $T_i$  的次数,记为  $tf(t_i, d)$ ; DF(Document Frequency)为特征项的文档频度,即在文档集合中出现特征项  $T_i$  的文档数,记为  $df(t_i)$ ; IDF(Inverse Document Frequency)为特征项的反文档频度,即

$$idf(t_i) = \log(n/df(t_i)) \quad (9.3)$$

其中,  $n$  表示训练样本的总数。

一般地,TF-IDF 中文档的向量表示  $D(W_1, W_2, \dots, W_n)$  中对应项  $T_i$  的权重  $W_i$  定义为:

$$W_i = tf(t_i, d) \times idf(t_i) \quad (9.4)$$

使用 TF-IDF 的明显优势是随着特征项  $T_i$  在文档  $D$  中出现次数的增加,  $tf(t_i, d)$  增大,这样特征项  $T_i$  的权重也随之增大,这与通常的理解相一致;如果特征项  $T_i$  在训练样本集合的许多文档中出现,则  $idf(t_i)$  将减小,这样特征项  $T_i$  的权重也随之减小,其对分辨文档类别的作用也将减小,这是因为如果特征项  $T_i$  的文档频度很高,则它分辨这些文档的能力相对减弱,所以使其权重减小,而那些更能分辨 Web 文档类别的特征项权重将增大。

采用 TF-IDF 算法在一定程度上减少了常用词对文档特征抽取的影响,突出重要的特征项,同时又考虑了整个文档集合中文档之间的关系,因此提取的特征具有较高的代表性。

### 3. 互信息

互信息(Mutual Information, MI)是统计模型中衡量两个随机变量  $X$ 、 $Y$  之间关联程度的常用参数。互信息越大,两个特征项之间的共现性就越大,同样,词和类别的互信息越大,说明词和类别的关系就越密切。可根据词和类别的互信息进行特征提取。

利用互信息提取特征的过程如下:

- (1) 初始情况下,该特征项集合包含所有该类别中出现的词。
- (2) 对于每个词,计算词和类别的互信息,即

$$M(W, C_j) = \log_2 \left( \frac{P(W | C_j)}{P(W)} \right) = \log_2 \frac{p(W, C_j)}{p(W) \times p(c_j)} \quad (9.5)$$

其中  $P(W, C_j)$  是训练样本中特征项  $W$  出现在类别  $C_j$  的频率,  $P(W)$  是训练样本中特征项  $W$  出现的频率。



- (3) 对于该类别中所有的词,依据计算的互信息大小排序。
- (4) 抽取一定数量的词作为特征项,具体需要选取多少特征项,目前还没有很好的确定方法,一般采用先确定初始值,然后根据实验测试和统计结果确定最佳值。
- (5) 将每一类别中所有的训练样本,根据抽取的特征项,进行向量维度压缩和精简。

## 9.4 Web 聚类

从国内外发展来看,Web 分类已取得了显著成效,尤其是美国、德国及英国等对此领域的探讨使 Web 分类在理论和实践上都有很大进步。相对而言,Web 聚类刚刚处于起步和发展阶段。目前,Web 聚类主要应用于模式识别、空间数据分析(在地理信息系统中,通过聚类发现特征空间建立主题索引;在空间数据挖掘中检测并解释空间中的簇)、图像处理、经济学(尤其是市场研究方面)以及互联网的文档分类和分析 Web 日志数据发现相似的访问模式。

Web 聚类是把一堆 Web 文档自动划分成不同的类别,任一类别内的 Web 文档与同类别内的其他 Web 文档的相似度大于该文档与其他类别文档之间的相似度。

一般地,Web 聚类步骤如下:

- (1) 模式表示,包括特征抽取以及将 Web 文档表示成可计算的形式。
- (2) 根据领域知识定义模式之间的距离度量公式。
- (3) 聚类/分组。
- (4) 评价输出结果。

目前,Web 聚类面临的主要挑战是:

- 一个 Web 文档可能包含多个主题,允许属于不同主题的 Web 文档归入多个不同的类别。
- 高维问题,即由于 Web 文档特征项维度过多而造成处理效率严重降低。
- 海量 Web 文档的处理效率。
- 聚类效果评价。

Web 聚类在智能信息检索、话题检测与跟踪、自动文摘等领域都有着非常广泛的应用。特别是在大规模情报分析、企业竞争情报、敏感社区发现和股情分析等方面具有很大优势,成为人们广泛研究和使用的 Web 挖掘工具之一。

Web 聚类的目标是使类内的距离尽可能的小,类间的距离尽可能的大,即相似的 Web 文档(距离小)尽可能聚在一起,不相似(距离大)的 Web 文档划分到不同的类。

相似度的计算方法有很多种。在采用向量空间表示 Web 文档的模型中,可以通过计算两个向量之间的相似度求得文档与类别之间的相似度,经常采用的是欧式距离,见式(9.6)。

$$D(S, T) = \left\{ \sum_i (S_i - T_i)^2 \right\}^{1/2} \quad (9.6)$$

按照 Web 文档表示方法的不同,可将现有的 Web 聚类分为基于词(word based)的、基于知识(knowledge-based)的和基于信息(information based)的三类。

### 1. 基于词

理论上,文本自动处理是以概念为基本处理单元,而词是概念的基本组成部分,是不可



再分的基本表意单元,是信息的基本载体。因此用词代表文本显然是可行的。这种方法需要较好的切分技术对文本进行切分,在此基础上这种方法的关键是合理选取可以代表文本主题内容的词汇,并据此对文本进行自动类别判定。

## 2. 基于知识

基于知识的自动 Web 聚类方法主要依赖于一个明确的知识库。知识的表示方法主要包括产生式、语义网络、框架、谓词、面向对象、粗糙集、神经网络、基于语言场和基于知识本体表示法等。基于知识聚类的显著特点是需要手工构建知识库,且构建的知识库领域性极强,可移植性较差。有研究工作表明,在一定的领域内,基于知识的自动 Web 聚类系统能够快速准确地进行文本归类。

## 3. 基于信息

基于信息的聚类是一种介于基于词的聚类和基于知识的聚类之间的方法。该方法对上下文敏感,是一种有选择的概念抽取技术。用于自动 Web 聚类技术中,只抽取对 Web 分类有用的信息,抽取短语及短语周围的内容和潜在的语义信息进行 Web 类别的确定。需要指出的是,这种方法可以用来处理没有关键词或关键短语的文章,并且避免了基于词的自动 Web 聚类在处理一词多义、一义多词、短语、局部文本以至全文文本时的局限性。

实现 Web 聚类的算法不少,主要包括平面划分聚类、层次聚类、基于网格的方法、基于密度的方法和基于模型的方法等。下面简要介绍平面划分法和层次聚类法。

### 1. 层次聚类法

层次聚类法是建立在给定数据对象集合的一个层次性的分解,根据层次分解形成的过程,这类方法可分为分裂(自顶向下)或合并(自底向上)。为了弥补合并或分裂的严格性,层次凝聚方法的聚类效果可以通过分析每个层次划分中的对象链接,或集成其他的聚类技术加以改进。

对于给定的 Web 文档集  $D = \{d_1, \dots, d_n\}$ ,层次聚类法的具体步骤如下:

- (1) 将文档集  $D = \{d_1, \dots, d_n\}$  中的每一文档  $d_i$  看作是一个具有单个成员的类  $C_i = \{d_i\}$ ,这些类构成  $D$  的一个聚类  $C = \{c_1, \dots, c_n\}$ ;
- (2) 计算  $C$  中每对类别  $(c_i, c_j)$  之间的相似度  $\text{sim}(c_i, c_j)$ ;
- (3) 选取具有最大相似度的类对  $\arg \max \text{sim}(c_i, c_j)$ ,并将  $c_i$  和  $c_j$  合并为一个新的类  $c_k = c_i \cup c_j$ ,从而构成一个新的聚类  $C = \{c_1, \dots, c_{n-1}\}$ ;
- (4) 重复上述步骤,直到  $C$  中只剩下一个类为止。

该过程构造出一棵生成树,其中包含了类的层次信息以及所有类内和类间的相似度。层次聚类方法是最常用的 Web 聚类方法,它能够生成层次化的嵌套类,而且准确度高。但是,在每次合并时需要全局地比较所有类别之间的相似度,并选择出最佳的两个类,因此运算速度比较慢,不适合大量文档的集合。

### 2. 平面划分法

平面划分法与层次聚类法的区别在于,它将 Web 文档集合水平地分割为若干类,而不是生成层次化的嵌套类。它首先得到初始  $k$  个划分的集合,参数  $k$  是划分簇的数量,然后采用迭代重定位技术,通过将对象从一个簇移到另一个簇优化划分。

将文档集  $D = (d_1, d_2, \dots, d_n)$  水平地分割为若干类,具体过程如下:

- (1) 确定生成的类的数目  $k$ ;



- (2) 按照某种原则生成  $k$  个聚类中心作为聚类的种子  $S = \{s_1, s_2, \dots, s_k\}$ ;
- (3) 对  $D$  中的每一文档  $d_i$ , 依次计算其与各个种子  $s_i$  的相似度  $\text{sim}(d_i, s_i)$ ;
- (4) 选取具有最大相似度的种子  $\arg \max \text{sim}(d_i, s_j)$ , 将  $d_i$  归入以  $s_i$  为聚类中心的类  $c_i$ , 从而得到  $D$  的一个聚类  $C = \{c_1, c_2, \dots, c_k\}$ ;
- (5) 重复步骤(2)~(4), 得到较为稳定的聚类结果。

该算法速度快, 但是必须事先确定  $k$  值, 且种子选取的好坏对聚类有较大影响。常见的平面划分法包括  $k$  均值和模糊  $c$  均值。

目前, 学术界对于 Web 聚类并没有统一标准的评价方法, 已有的评价方法多借鉴信息检索或文本分类方面的评价方法。

## 9.5 Web 分类

Web 分类是指按照预先定义的分类体系, 将 Web 文档集合的每一文档归入某一类别。这样, 不但能够方便用户浏览文档, 而且可以通过限制搜索范围使文档的查找更为容易。目前, Yahoo 仍然是通过人工对 Web 文档进行分类, 这大大限制了其索引页面的数目和覆盖范围。可以说研究 Web 分类有着广泛的商业前景和应用价值。

文本特征指的是关于文本的元数据, 分为描述性特征(例如文本的名称、日期、大小和类型等)以及语义性特征(例如文档的作者、机构、标题、内容等)。对于内容这个难以表示的特征, 首先要找到一种能够被计算机处理的表示方法。

VSM 是近年来应用较多且效果较好的方法之一。该模型中, Web 文档被看做是由一组正交词条矢量所组成的矢量空间, 每个 Web 文档表示为其中的一个规范化特征矢量, 用 Web 文档中出现的所有单词表示其内容特征。预处理的过程首先排除出现频率高但是含义虚泛的词语, 例如英文中的 *a, the, each, for*, 汉语中的“地、得、的、这、虽然”等; 然后排除那些在 Web 文档集合中出现频率很低的单字; 在英文中还可以去除前缀, 保留词根, 如 *walker, walking* 和 *walked* 都可以是同一个词 *walk*。

Web 分类是有指导的机器学习, 即利用预定义的分类类别和训练样本集指导学习, 预测待分类样本的类别。

从数学角度而言, Web 分类可定义为文档集  $D = \{d_1, d_2, \dots, d_j\}$ , 类集  $C = \{c_1, c_2, \dots, c_j\}$ , 确定任意一个元组  $\langle d_j, c_i \rangle$  映射到集合  $\{T, F\}$  上的值, 故 Web 分类本质上是一个函数  $D \times C \rightarrow \{T, F\}$ 。

广义而言, Web 分类是数据挖掘的一种, 但与传统数据挖掘不同的是, Web 分类面对的是半结构化或非结构化的数据。目前 Web 分类最普遍的实现方法是将 Web 文档结构化后, 再运用传统的分类算法。

Web 分类过程如图 9.4 所示, 首先对 Web 文档进行预处理, 将 Web 文档用模型表示, 并进行特征提取; 然后构造并训练分类器; 最后利用分类器对类别未知的 Web 文档进行分类。

Web 分类基本上都需要经过训练和测试两个阶段, 按照 Web 分类的定义, 训练过程就是寻找映射函数的过程, 即构建分类器; 测试阶段是利用训练生成的模型, 自动完成分类。

根据 Web 文档表示模型的区别, 可以将 Web 分类算法分成基于特征独立性的算法和



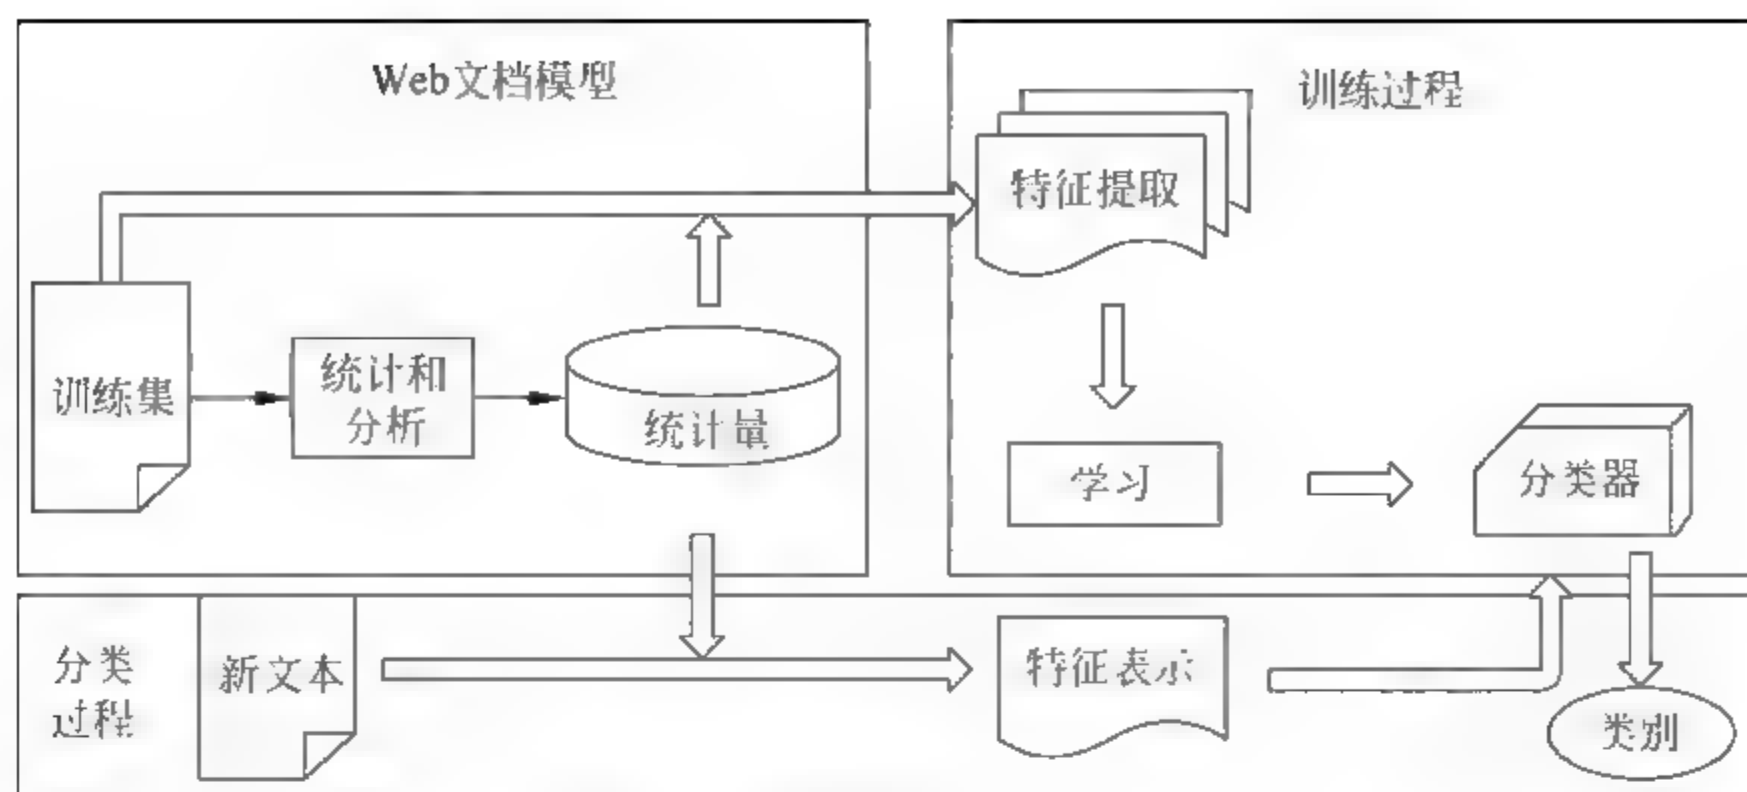


图 9.4 Web 分类过程

基于特征依赖性的算法。基于特征独立性算法忽略了 Web 文档内词汇或短语之间的语义关系, Web 文档被表现为分量间关系独立的向量, 主要利用数理统计方法将 Web 分类问题转换为数学分析, 包括相似度模型、概率模型、线性模型、非线性模型和组合模型等。

在相似度模型中, 一种方法是计算 Web 文档与代表某一 Web 文档类别的中心向量之间的相似度  $\text{sim}(d_k, c_i)$ 。其中类别的中心向量是根据测试文档统计计算的估计值。类别的中心向量的计算包括算术平均、频率的加权平均和 Rocchio 公式等, 相似度的计算方法有多种, 常用的包括:

(1) 词条重复率, 即只考虑两个特征向量所包含词条的重复程度, 见式(9.7)。

$$\text{sim}(d_k, c_i) = \frac{n_I(d_k, c_i)}{n_Y(d_k, c_i)} \quad (9.7)$$

其中,  $n_I(d_k, c_i)$  是  $V(d_k)$  和  $V(c_i)$  具有的共同词条数目,  $n_Y(d_k, c_i)$  是  $V(d_k)$  和  $V(c_i)$  具有的所有词条数目。

(2) 夹角余弦, 即考虑两个特征向量之间夹角的余弦, 见式(9.8)。

$$\text{sim}(d_k, c_i) = \frac{V(d_k) \cdot V(c_i)}{BV(d_k)B \times BV(c_i)B'} \quad (9.8)$$

其中,  $V(d_k) \cdot V(c_i)$  为标准向量点积。

(3) 欧几里德距离, 即两个向量的空间距离, 见式(9.9)。

$$\text{sim}(d_k, c_i) = \sqrt{\sum_{j=1}^n (d_{kj} - c_{ij})^2} \quad (9.9)$$

另一种方法不需要建立描述 Web 文档类别的中心向量, 而是依赖于测试文档与训练文档之间的相似度。典型算法是 k 近邻算法, 算法的主要思路是计算训练文档与测试文档距离最近的  $k$  个 Web 文档(即  $k$  个近邻), 根据这  $k$  个 Web 文档的类别判定待分类 Web 文档的类别。

### 9.5.1 朴素贝叶斯

朴素贝叶斯(Naive Bayes, NB)是概率模型的典型算法, 其主要思想是基于贝叶斯假设, 即 Web 文档中的词汇在确定文档类别的作用上相互独立。它首先计算特征词属于每个

类别的先验概率,根据特征词的先验概率计算该 Web 文档属于每一类别的后验概率,最后取后验概率最大的类别作为分类结果。很多学者对朴素贝叶斯算法进行了改进,如增强型朴素贝叶斯算法、与潜在语义索引结合的贝叶斯方法以及贝叶斯层次分类等。

若 Web 文档向量的分量为相应的词在 Web 文档中出现的频度(即 TF 表示法),则采用该方法表示的 Web 文档属于类  $c$  的概率为:

$$P(c/\text{Doc}) = \frac{P(c) \prod_{F_i \in V} P(F_i/c)^{\text{TF}(F_i, \text{Doc})}}{\sum_i P(c_i) \prod_{F_i \in V} P(F_i/c_i)^{\text{TF}(F_i, \text{Doc})}} \quad (9.10)$$

$$P(F_j/c) = \frac{1 + \text{TF}(F_j, c)}{|V| + \sum_i \text{TF}(F_i, c)} \quad (9.11)$$

其中,  $P(c)$  为一个 Web 文档属于类  $c$  的概率,  $P(F_j/c)$  是对  $c$  类文档中特征  $F_j$  出现的条件概率的拉普拉斯概率估计,  $\text{TF}(F_j, c)$  是  $c$  类文档中特征  $F_j$  出现的频度,  $V$  为单字辞典集的大小,等于 Web 文档表示中所包含的不同特征的总数目,  $\text{TF}(F_j, \text{doc})$  是在 Web 文档中特征  $F_j$  出现的频度。

虽然条件独立性假设对词汇在 Web 文档中出现不是很适合,但 NB 是一种有效的方法。

NB 算法的步骤如下:

Learn\_Native\_Bayes(Docs,  $V$ )

(1) 收集 Docs 中所有词汇。

(2)  $\text{vocabulary} \leftarrow$  Docs 中 Web 文档出现的所有词汇集合。

(3) 计算概率  $P(V_j)$  和  $P(w_k | V_j)$ 。

① 对  $V$  分类集中的每一个目标值  $V_j$ , 有

$\text{docs} \leftarrow$  Docs 中类标签  $V_j$  的 Web 文档子集

$P(V_j) \leftarrow |\text{docs}| / |\text{Docs}|$

$n \leftarrow$  在 docs 中不同词汇的总数

② 对 vocabulary 中每个词汇  $w_k$ , 有

$n_k \leftarrow$  词汇  $w_k$  在  $\text{docs}_j$  中出现的次数

$P(w_k | V_j) \leftarrow \frac{n_k + 1}{n + |\text{vocabulary}|}$

贝叶斯分类的特点是:

(1) 贝叶斯分类并不把一个对象绝对地指派给某一类,而是通过计算得出属于某一类的概率,具有最大概率的类便是该对象所属的类别。

(2) 一般情况下,贝叶斯分类中所有的属性都潜在地起作用,即并不是一个或几个属性决定分类,而是所有的属性都参与分类。

(3) 贝叶斯分类对象的属性值可以是离散的、连续的,也可以是混合的。

贝叶斯定理给出了最小化误差的最优解决方法,可用于分类和预测。理论上很完美,但实际中并不能直接应用,因为需要知道数据的确切分布概率,而实际上并不能确切地给出。因此在很多 Web 分类算法中都会做出某种假设以逼近贝叶斯定理的条件独立性假设。



### 9.5.2 其他方法

支持向量机(Support Vector Machines, SVM)是对结构风险最小化原则的近似,该算法的主要思想是在给定的训练集上,作一个超平面的线性划分,将分类问题转化为一个寻找空间最优平面的问题,再次转化成一个二次规划问题。原因是如果所有的向量都能够被某个超平面正确划分,并且各类向量与超平面的最小距离最大化(即边缘最大化),则该超平面为最优超平面,距离平面最近的异类向量为支持向量,一组支持向量可以唯一确定一个超平面。

VSM是由Salton等人于20世纪60年代末提出。这是最早也是最著名的信息检索的数学模型。其基本思想是将Web文档表示为加权的特征向量 $D(T_1, W_1; T_2, W_2; \dots; T_n, W_n)$ ,然后通过计算文本相似度确定待测样本的类别。当Web文档被表示为空间向量模型时,其相似度就可以借助特征向量之间的内积表示。

实际应用中,VSM一般事先依据语料库中的训练样本和分类体系建立类别向量空间。当需要对待测样本进行分类时,只需要计算待测样本和每一个类别向量的相似度即内积,然后选取相似度最大的类别作为待测样本所对应的类别。

由于VSM需要事先计算类别的空间向量,而该空间向量的建立又很大程度依赖于该类别向量的特征项。研究发现,类别中所包含的非零特征项越多,所包含的每个特征项对于类别的表达能力越弱。因此,VSM相对其他分类方法而言,更适合于专业文献的分类。

### 9.5.3 评价

通常,Web分类准确率的评价包括保留和交叉验证两种方法,它们都假定待分类样本和训练样本具有同样的分布。

(1) 保留(holdout):数据集的一部分(通常是2/3)作为训练集,剩余部分用作测试集。利用训练集构造分类器,然后使用这一分类器对测试集样本进行分类,即评估分类器的准确率。

虽然这种方法速度快,但由于仅使用2/3的数据构造分类器,并没有充分利用所有的样本进行学习训练。如果使用所有的样本,那么可能构造出更精确的分类器。

(2) 交叉验证(cross validation):数据集被划分为 $k$ 个没有交叉的子集,所有子集的大小大致相同。分类器训练和测试 $k$ 次;每次分类器使用一个子集的剩余数据作为训练集,然后在该子集上进行测试。最终取所有准确率的平均值作为评估结果。

交叉验证方法可以重复执行多次,对于一个 $t$ 次 $k$ 分的交叉验证, $k \times t$ 个分类器被构造并被评估,这意味着交叉验证的时间是分类器构造时间的 $k \times t$ 倍。增加重复的次数意味着运行时间的增长和准确率的改善。我们可以对 $k$ 值进行调整,减少到3或5,这样可以缩短运行时间。然而,减小训练集有可能使评估产生较大的偏差。

通常,保留评估法用于最初的探索性试验,或者数据量多于5000的数据集;交叉验证法用于建立最终的分类器,或者很小的数据集。

Web分类的评价指标主要包括:



- (1) 准确率 模型正确预测未知数据的能力。
- (2) 速度 构建和使用模型花费的时间。
- (3) 健壮性 有噪声或缺失数据时模型正确分类或预测的能力。
- (4) 伸缩性 对于大数据量,有效构造模型的能力。
- (5) 可解释性 模型提供的理解和观察的层次。

Web 分类常用的评估指标包括分类正确率、查准率 (precision rate)、查全率 (recall rate)、F 值、宏平均和微平均等。其中,分类正确率定义为所有正确分类的样本数与整个测试样本数之比。查准率和查全率又称为精确率和召回率,是信息检索的评估指标,同时也适用于 Web 分类。查准率是指分类器判定的属于类别  $C_i$  的所有文档中,确实属于类别  $C_i$  的文档所占的比例,即:

$$p = \text{实际正确分类的文档数} / \text{分类器分为类 } C_i \text{ 的文档总数}$$

查全率是指原本属于类别  $C_i$  的所有文档中,分类器正确判定的文档所占的比例,即:

$$r = \text{实际正确分类的文档数} / \text{原本属于类 } C_i \text{ 的文档总数}$$

微平均计算所有类别中正确分类和错误分类的样本总数,再求查准率和查全率;宏平均首先计算各个类别的查准率和查全率,然后取算术平均。目前,关于哪种评估方法最好还没有定论。

F 值是由 C. J. Van Rijsbergen 提出,其定义为:

$$F = \frac{2}{\frac{1}{r} + \frac{1}{p}} = \frac{2rp}{r+p} \quad (9.12)$$

其中, $r$  是查全率, $p$  是查准率, $F$  通过赋予查准率和查全率相同的权重平衡对两者的评价。

实际中,影响 Web 分类准确率的主要因素包括:

- (1) 训练集的样本数量。因为利用训练样本对分类器进行学习和训练,所以训练集越大,分类器性能越可靠。然而,训练集越大,构造分类器所需训练学习的时间就越长。分类准确率随训练集规模的增大而提高。
- (2) 属性的数目。更多的属性对于分类器而言意味着计算更多的组合,计算时间更长。有时随机关系会将分类器引入歧途,导致可能构造的分类器准确率不高(又称过度拟合)。因此,如果我们通过常识分析和判断某个属性与分类无关,则将其删除。
- (3) 属性的信息。有时分类器无法从属性中获取足够的特征进行分类和预测,如试图根据某人眼睛的颜色预测其收入,可考虑引入其他属性,如职业、每周工作小时数和年龄等,以提高准确率。
- (4) 待测样本的分布。如果待测样本不同于训练样本的分布,则分类准确率可能很低。例如利用家用型轿车的训练集构造的分类器,试图用它对运动型轿车进行分类可能没有什么意义,因为样本特征的分布可能差别很大。



## 第 10 章 数据挖掘实例

本章主要面向电信领域,基于客户的计费、账务、通话详单和客户资料等海量数据,运用数据挖掘算法和工具,针对客户细分、重入网识别和 WAP 日志挖掘等专题分析进行详细介绍。

### 10.1 TOM 和 eTOM

为了了解电信行业的特点,深刻理解各种专题分析提出的背景以及对于提高电信运营商核心竞争力和辅助经营决策的重要意义,首先简要介绍 TOM 和 eTOM 规范。

#### 1. TOM

虽然世界各国的电信企业各有各的特点,但是电信行业具有其自身固有的一般性运营模式。电信管理论坛(TeleManagement Forum, TMF)提出的电信运营图(Telecom Operations Map, TOM)涵盖了电信运营的一般业务流程,是电信运营管理事实上的国际标准。

TOM 以 TMN(Telecommunications Management Network, 电信管理网)模型为基础。TMN 提供电信服务的运营支撑和管理, TOM 则注重 TMN 网元层以上的运营管理。实现电信和数据业务端到端流程的自动化是电信运营商整合运营支撑系统的主要目标之一, TOM 则是实现这一目标的业务流程框架。

TOM 使用分层且通用的方法描述电信运营商运营方式及其业务结构,是描述操作流程的通用视图。其重点是电信运营商使用的业务流程、流程之间的连接、接口的确定以及各流程对客户、服务和网络等信息的使用情况。

TOM 并没有包含运营流程中每一个可能的视图,只是提供了一般性的框架以规范一个单独的电信运营商如何开发和执行其流程。每家电信运营商依据自身的业务目标和策略,以及适用的业务规则和政策开发和更新流程。TOM 的业务流程框架如图 10.1 所示。

由图 10.1 可知, TOM 把电信业务纵向地划分为客户接口管理、客户关怀、业务开发及运行、网络 and 系统管理四个流程。

(1) 客户接口管理流程直接与客户交互,将客户的需求和查询转化为相应的“事件”,如新建订单、账单调整等。

(2) 客户关怀流程处理与客户相关的工作,是面向客户的流程。包括销售、客户订购处理、问题处理、客户 QoS 管理以及发票和收费等模块。

(3) 业务开发及运行流程管理业务开发和业务运行等,是面向业务的流程。包括业务开发、业务配置和业务管理等模块。

(4) 网络和系统管理流程是面向网络资源的流程。包括网络计划、网络提供、网络维护和恢复等模块。

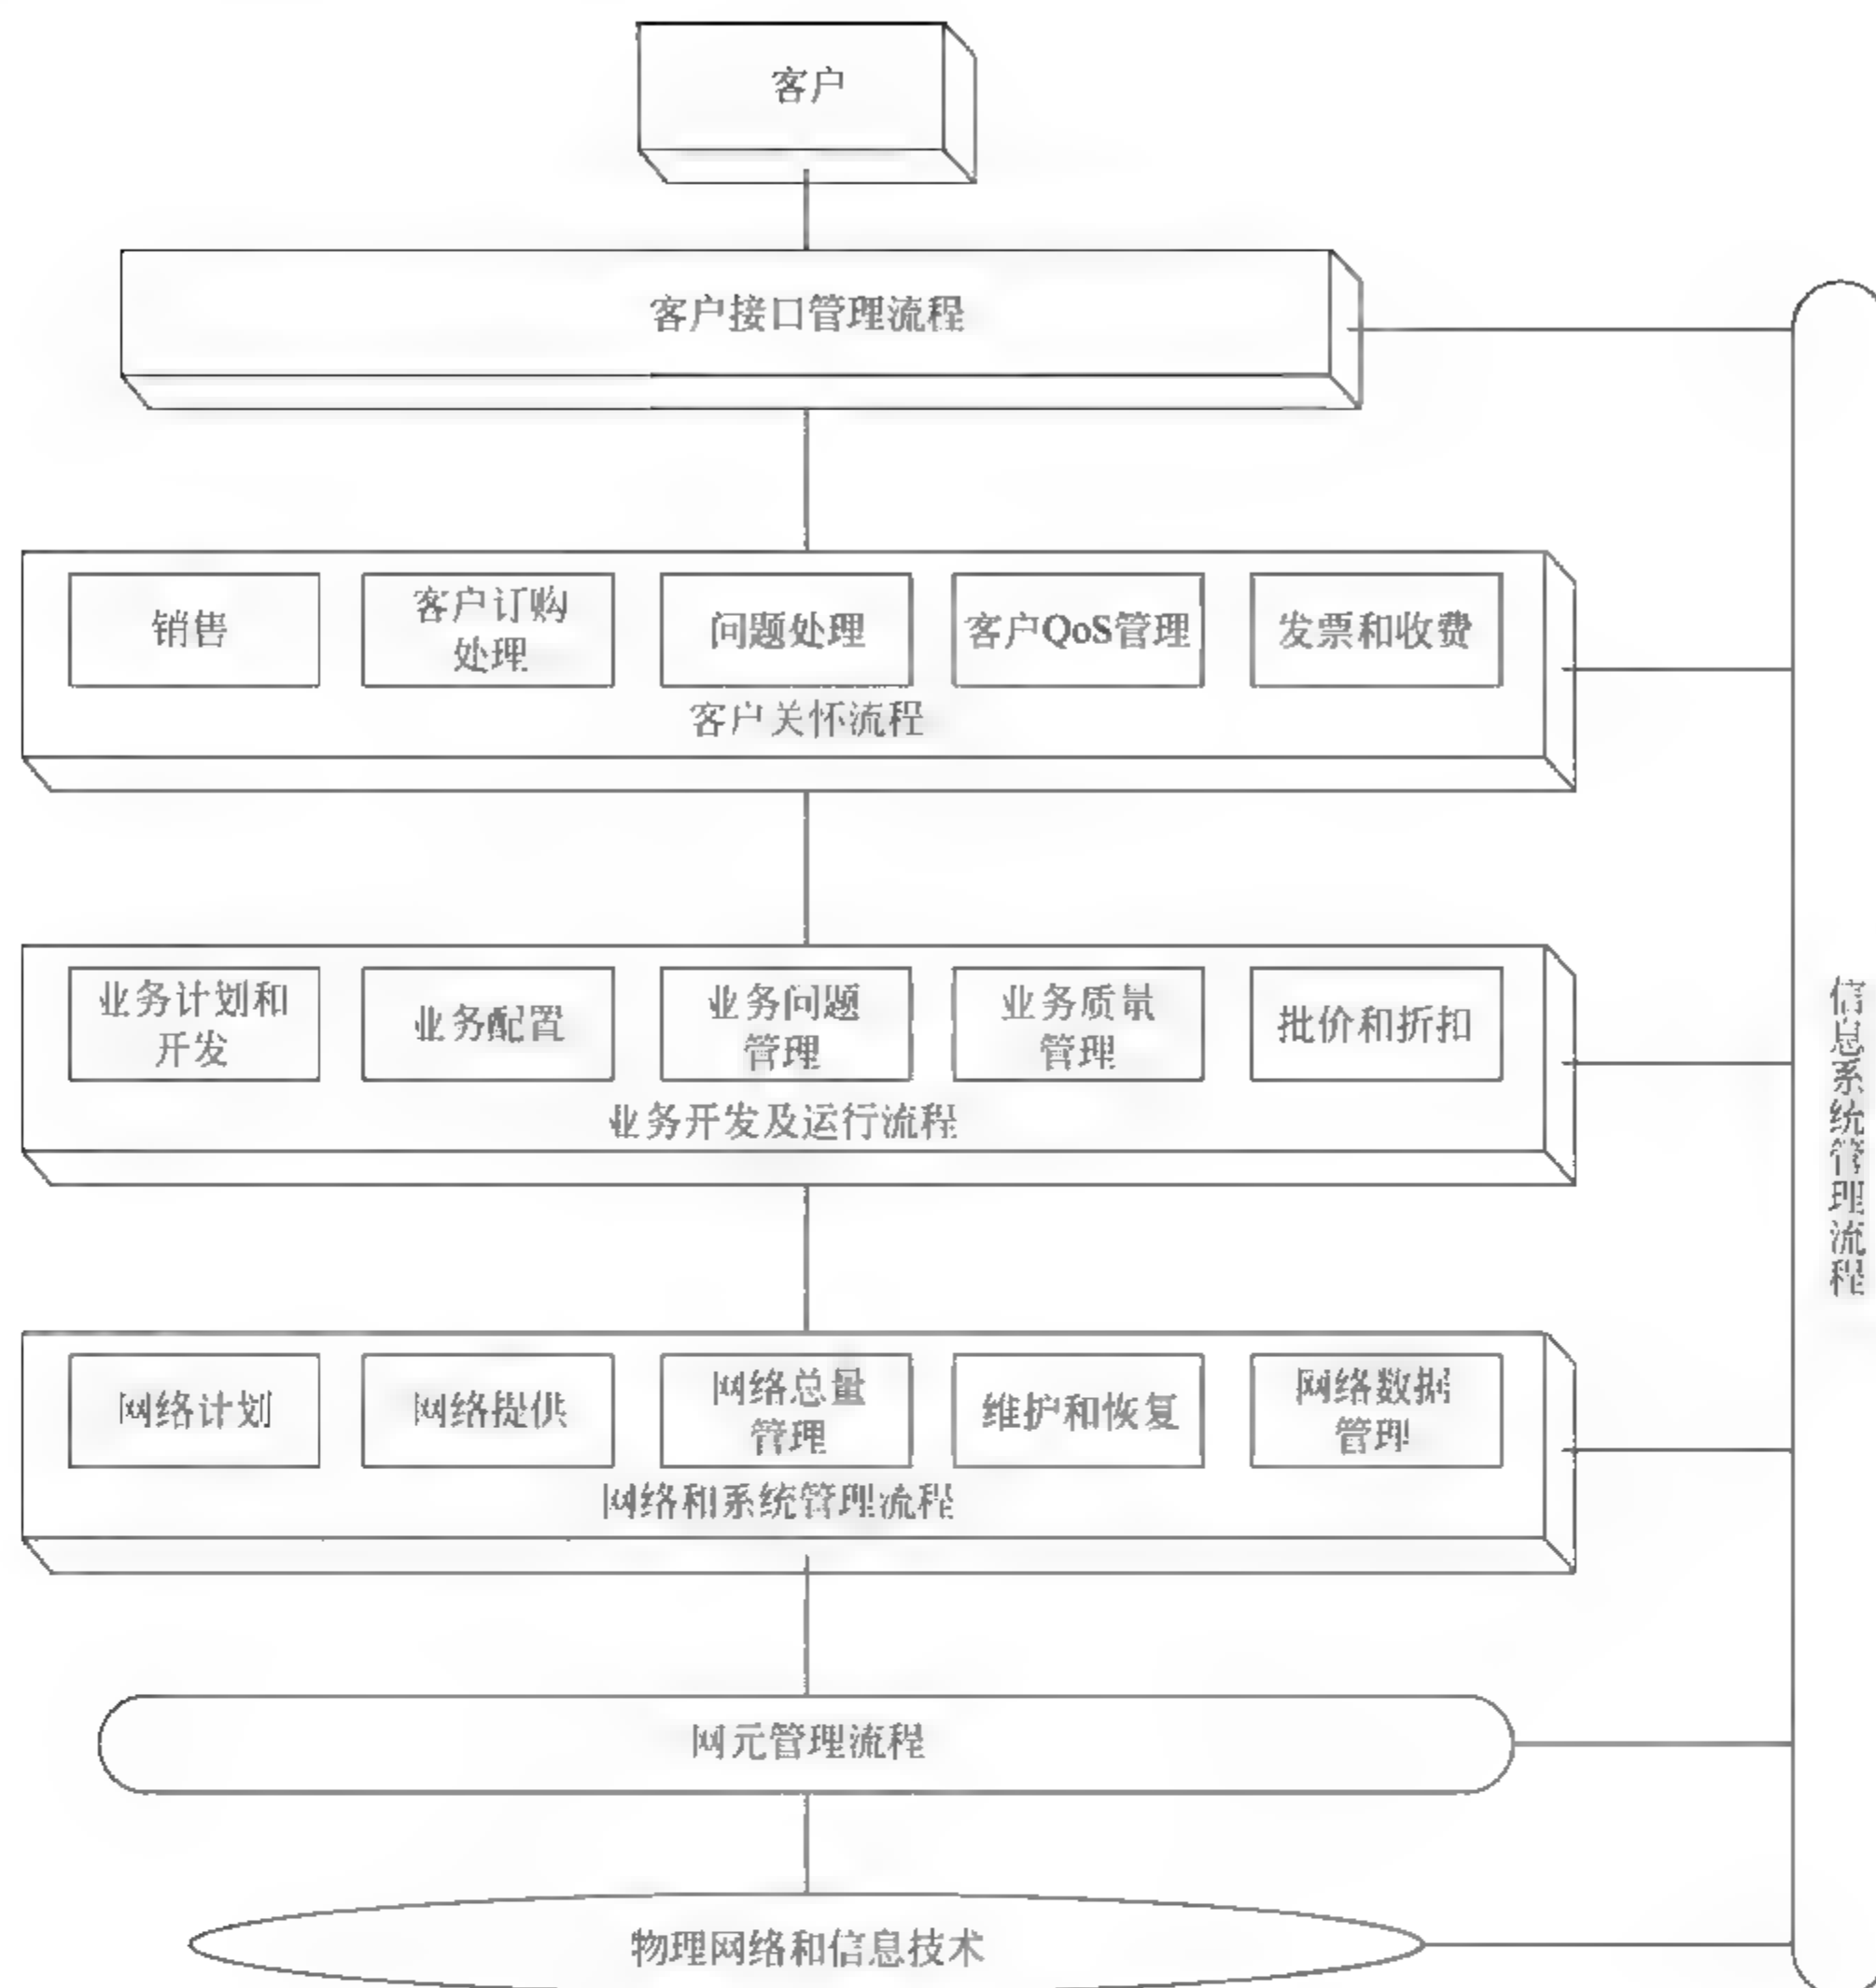


图 10.1 TOM 的业务流程框架

在上述业务流程框架的基础上,TOM 把电信业务流程划分为端到端的多个组成部分,对每个组成部分定义了功能以及其对上和对下的连接点(接口),从而为整个电信业务实现自动化和可配置提供框架。

此外,TOM 把电信运营流程横向地划分为业务实现(service fulfillment)、业务保障(service assurance)和业务计费(service billing)三部分,如图 10.2 所示。

(1) 业务实现是指所提供业务的开通方面。包括销售、业务开发和网络提供等模块,保证及时地向客户提供正确的业务。

(2) 业务保障是指如何维护业务的正常运行。包括客户 QoS 管理、业务质量管理、网络维护和恢复等模块,保证向客户提供高质量的服务。

(3) 业务计费是指与账务有关的功能。包括收费、批价和网络数据管理等模块,保证及时准确地向客户收取费用。



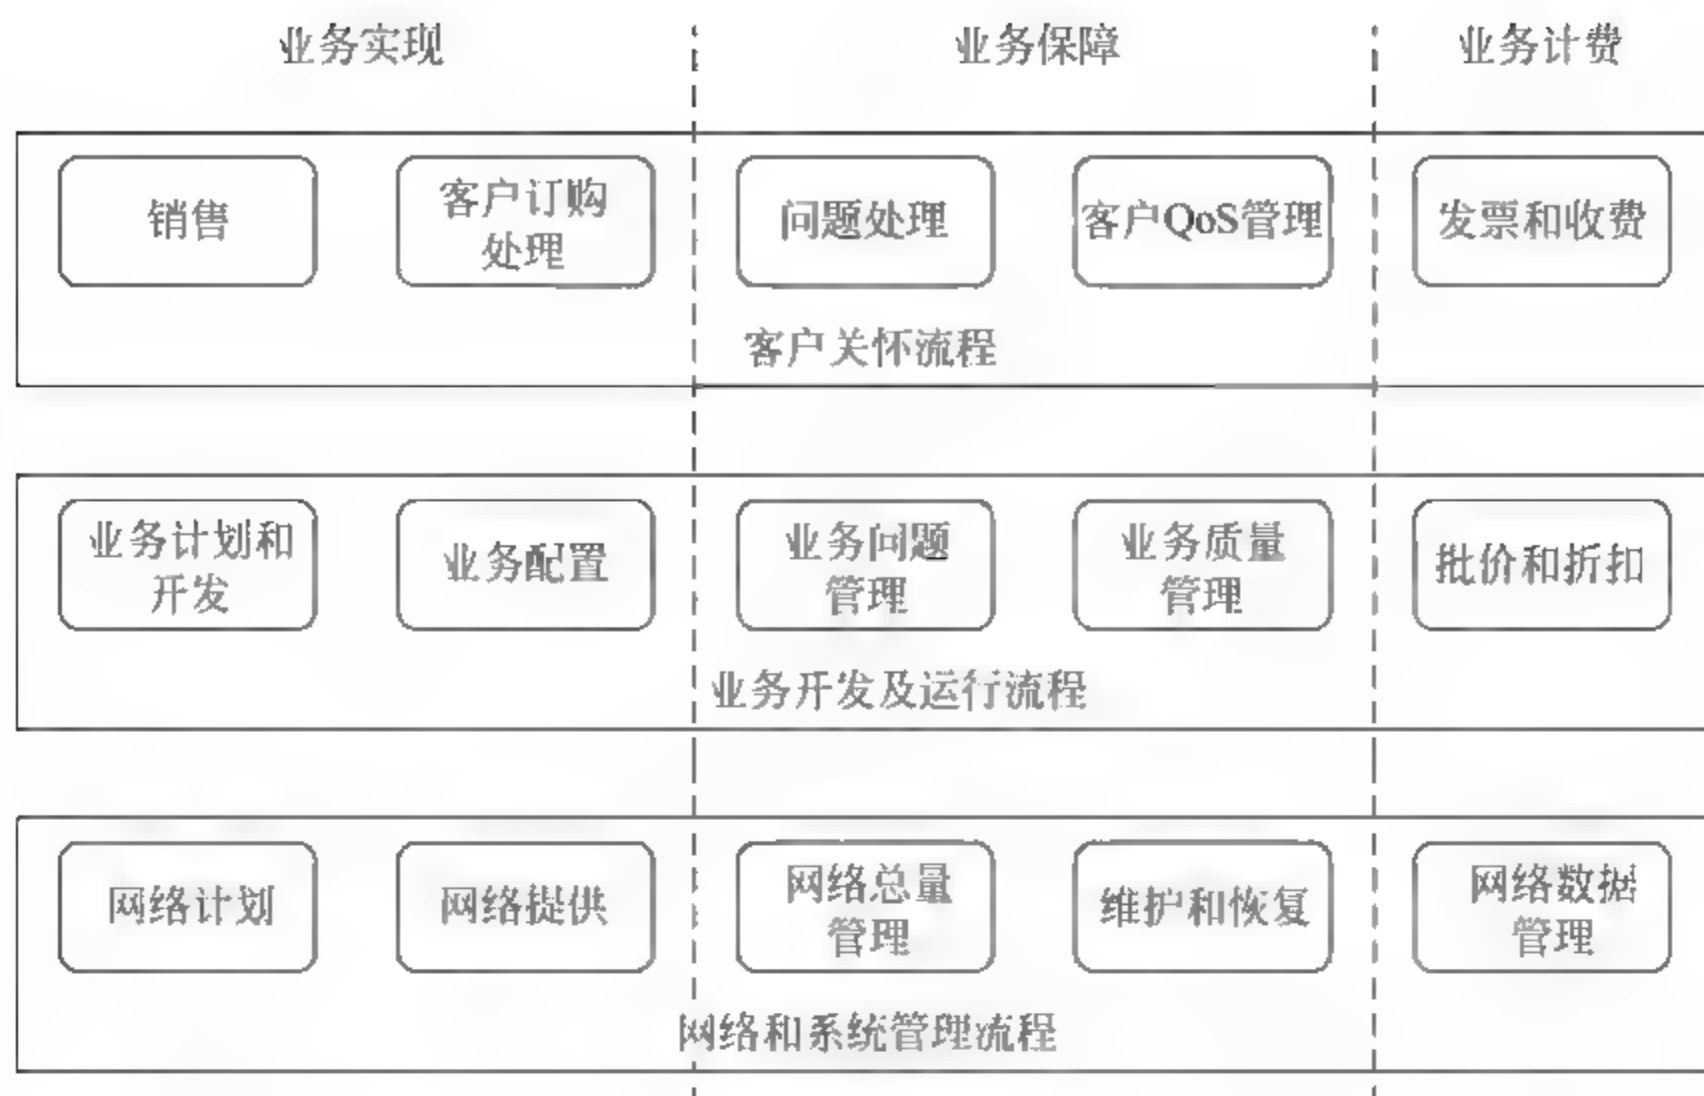


图 10.2 业务实现、保障和计费(Fulfillment, Assurance, Billing, FAB)端到端流程的分割

## 2. eTOM

eTOM是由TMF提出的一个业务流程模型,或称业务流程框架(business process framework),能够为服务提供商提供企业的业务流程。eTOM源于TOM并扩展了TOM,是一个更详细、更成熟的标准。它提供针对服务提供商的完整的企业业务流程框架,并结合了新的电子商务(eBusiness)方面的内容。eTOM框架涵盖了整个企业的范围,而且适应电子商务环境对企业的影响。eTOM的整体流程框架如图10.3所示。

eTOM旨在为行业展现这样一个前景,即通过使用业务流程驱动的方式管理企业,帮助企业在竞争中获胜。保证所有与服务的提供和支持相关的、关键的企业支撑系统之间的整合,这也是eTOM的目的之一。eTOM主要关注于服务提供商使用的业务流程,这些业务流程之间的互连关系,接口的确定和定义,以及被多个业务流程所使用的关于客户、服务、资源和供应商/合作伙伴等各方面的信息。在电子商务环境中,通过自动化提高生产能力,增加利润和改善客户关系,这是至关重要的。

eTOM继承了TOM注重业务流程、客户驱动、自顶向下的模型设计和广泛适用等优势。同时不同于TOM,eTOM是针对服务提供商完整的企业业务流程框架,并结合了新的电子商务方面的内容。

eTOM自顶向下提供不同粒度的业务流程框架图,由图10.3可知eTOM把企业业务流程分为三大部分,即:

(1) 策略、基础设施和产品包括策略的设计开发、基础设施建设、产品管理以及供应链的开发管理。在eTOM中,基础设施不仅包括支撑业务和产品的IT和资源基础设施,还包括一些支撑功能性流程(例如客户管理流程等)的基础设施。

(2) 运营流程是eTOM的核心部分,包括所有客户业务和相关管理的运营流程(含与客户直接接触的流程)、日常的运营支持和运营准备、销售管理、供应商和伙伴关系管理等。这一部分继承了TOM中的业务实现、业务保障和业务计费等几个部分,同时增加了运营支

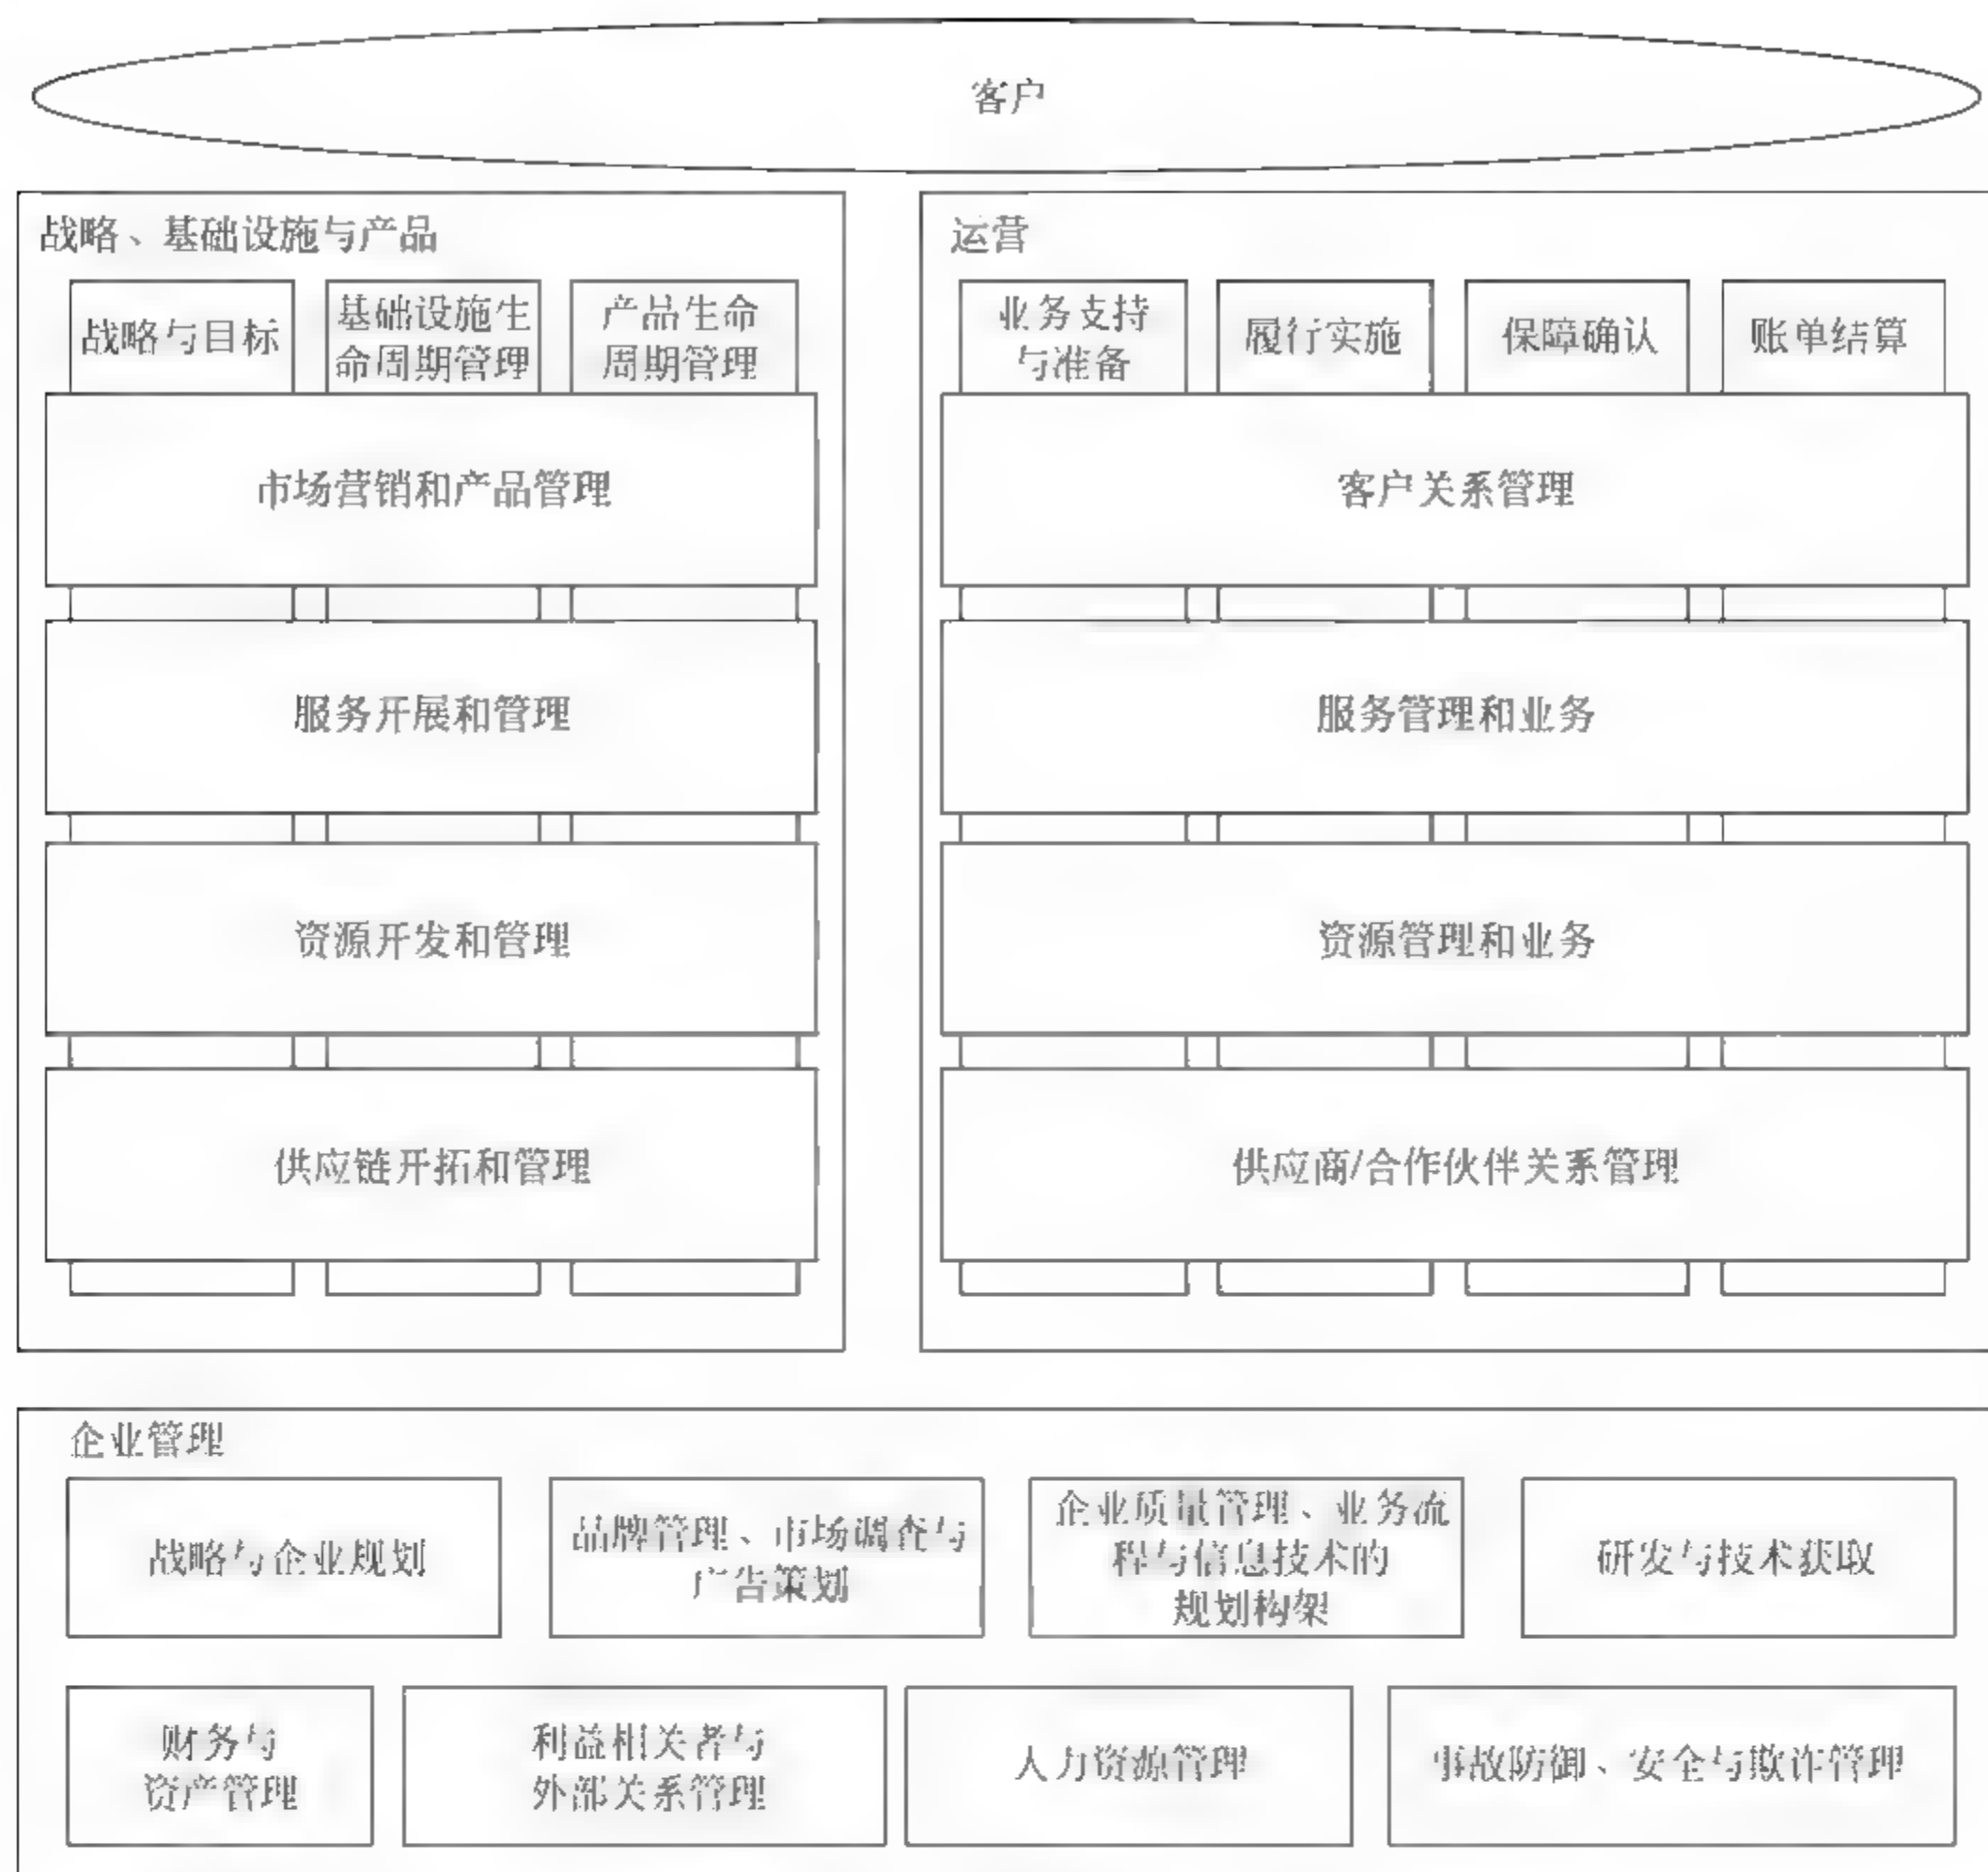


图 10.3 eTOM 的整体流程框架

持和准备部分。

(3) 企业管理流程包括运营任何业务都需要的一些基本流程。这些流程注重于企业层的流程和目标,与几乎其他所有的流程都有接口,一般是公司的职能或者流程,例如财政管理和人力资源管理流程等。

TMF 还从其他的视角探讨了电信运营的框架,如系统集成图(System Integration Map, SIM)、技术集成图(Technology Integration Map, TIM)等一系列标准,由于篇幅所限不再赘述,详细资料可浏览 TMF 网站(<http://www.tmforum.org>)。

TOM 与客户关系管理(Customer Relationship Management, CRM)有关的部分包括客户接口管理流程和客户关怀流程,其中客户关怀流程注重业务处理方面,CRM 理念更主要体现在客户接口管理流程中。依赖于运营商,客户接口管理可以是单个的客户关怀流程也可以是多个流程的组合,描述支持客户关怀流程的客户接口功能,例如集成的客户接口管理、语音应答单元和 Web 接口支持。

eTOM 重点明确了 CRM 的定位,对 CRM 模块的描述比 TOM 更详细和具体。eTOM



中位于第二层的 CRM 流程框架如图 10.4 所示。

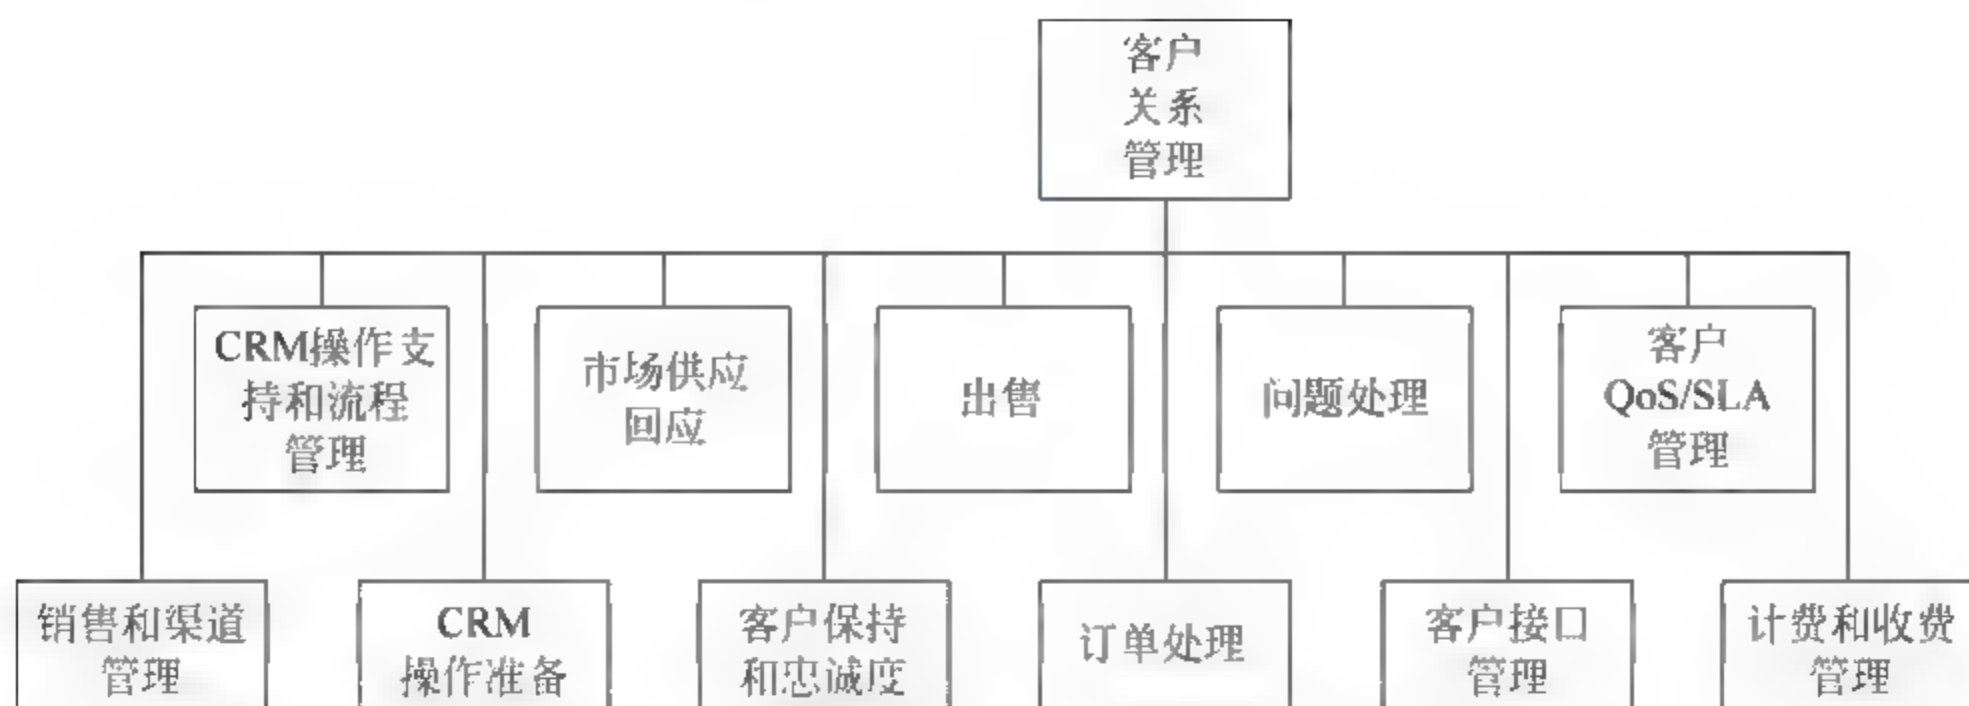


图 10.4 eTOM 中第二层的 CRM 流程框架

由图 10.4 可知,eTOM 中 CRM 的功能非常强大,不仅包括 TOM 中的客户接口管理功能,而且还包括客户保持和忠诚度等功能。

数据挖掘作为一种数据深入分析的手段,不仅可以对图 10.4 中的客户保持和忠诚度、客户 QoS/SLA 管理等模块提供支持,而且是企业管理部分市场调查和分析、知识管理等的重要技术手段。

基于 TOM 和 eTOM 规范构建的电信企业 IT 总体架构如图 10.5 所示。

其中,CRM 系统的核心思想是将企业客户(包括最终客户、分销商和合作伙伴)作为最重要的企业资源,通过完善的客户服务和深入的客户分析满足广大客户需要,保证实现客户终生价值。

CRM 也是一种管理软件和技术,将最佳的商业实践与数据挖掘、数据仓库、一对一营销、销售自动化以及其他信息技术紧密结合在一起,为企业营销、客户服务和决策支持等提供一个自动化的解决方案,使企业拥有基于电子商务面向客户的平台,以顺利地实现由传统企业模式向以电子商务为基础的现代企业模式的转变。

可见,CRM“以客户为中心”的理念要求企业必须完整地认识整个客户生命周期,提供与客户沟通有效的统一平台,提高员工与客户接触效率和客户反馈率,提高客户忠诚度、满意度以及降低企业经营成本,提升客户价值,最终提高企业收入和利润。

CRM 系统的基本功能包括客户管理、产品管理、联系人管理、营销管理、潜在客户管理、销售管理、电话营销和客户服务,有些还涉及 workflow 管理、呼叫中心、合作伙伴管理、知识管理、商业智能和电子商务等。

CRM 系统主要分为运营型、分析型和协作型三种。

#### 1) 运营型 CRM(Operational CRM)

运营型 CRM 建立在客户管理对于企业成功具有很重要的作用这一理念上,要求所有业务流程自动化,全面提高企业同客户的交流能力。

运营型 CRM 的应用主要体现在以下五个方面。

(1) 销售套件 为企业管理销售业务的全过程提供丰富强大的功能,包括销售信息管理、销售过程定制、销售过程监控、销售预测和销售信息分析等。运营型 CRM 销售套件将是销售人员关注客户、把握机会、完成销售的有力工具,并有助于提高销售能力。它对企业的典型作用是帮助企业管理并跟踪从销售机会产生到结束各销售阶段和环节的全程信息和动作。




图 10.5 电信企业 IT 总体架构



(2) 营销套件 为企业全程掌握市场营销活动的运作提供便利,提供市场营销活动信息管理、计划预测、项目追踪、成本明细、回应管理和效果评估等功能,帮助企业管理者清楚了解所有市场营销活动的成本和投资回报。

(3) 服务套件 帮助企业以最低成本为客户提供周到、及时和准确的服务,提供包括服务请求及投诉的创建、分配、解决、跟踪、反馈、回访等相关服务环节组成的闭环式处理模式,帮助企业维系和挽留老客户、发展新客户。

(4) 电子商务套件 旨在企业商务过程e化,帮助企业将门户网站、各种营销渠道集成在一起,开拓新的营销渠道和商务处理模式。

(5) 平台 是产品的基础核心平台,能够实现产品的基础数据维护、安全控制、动态配置和工作流定制等功能。

## 2) 分析型 CRM (Analytical CRM)

分析型 CRM 主要是分析从原有业务系统中获得的各种数据,进而为企业的经营决策提供可靠的量化依据。一般地,分析型 CRM 需要使用一些诸如数据仓库、OLAP 和数据挖掘等数据管理和分析工具。

分析型 CRM 的销售、服务、市场、电子商务以及业务平台等功能可将客户的各种信息按照分析需求进行整合,通过建立不同的模型,对不同客户群采用针对性的和有效的互动交流。涉及的核心技术包括数据仓库、OLAP 和数据挖掘等,分析型 CRM 如图 10.6 所示。

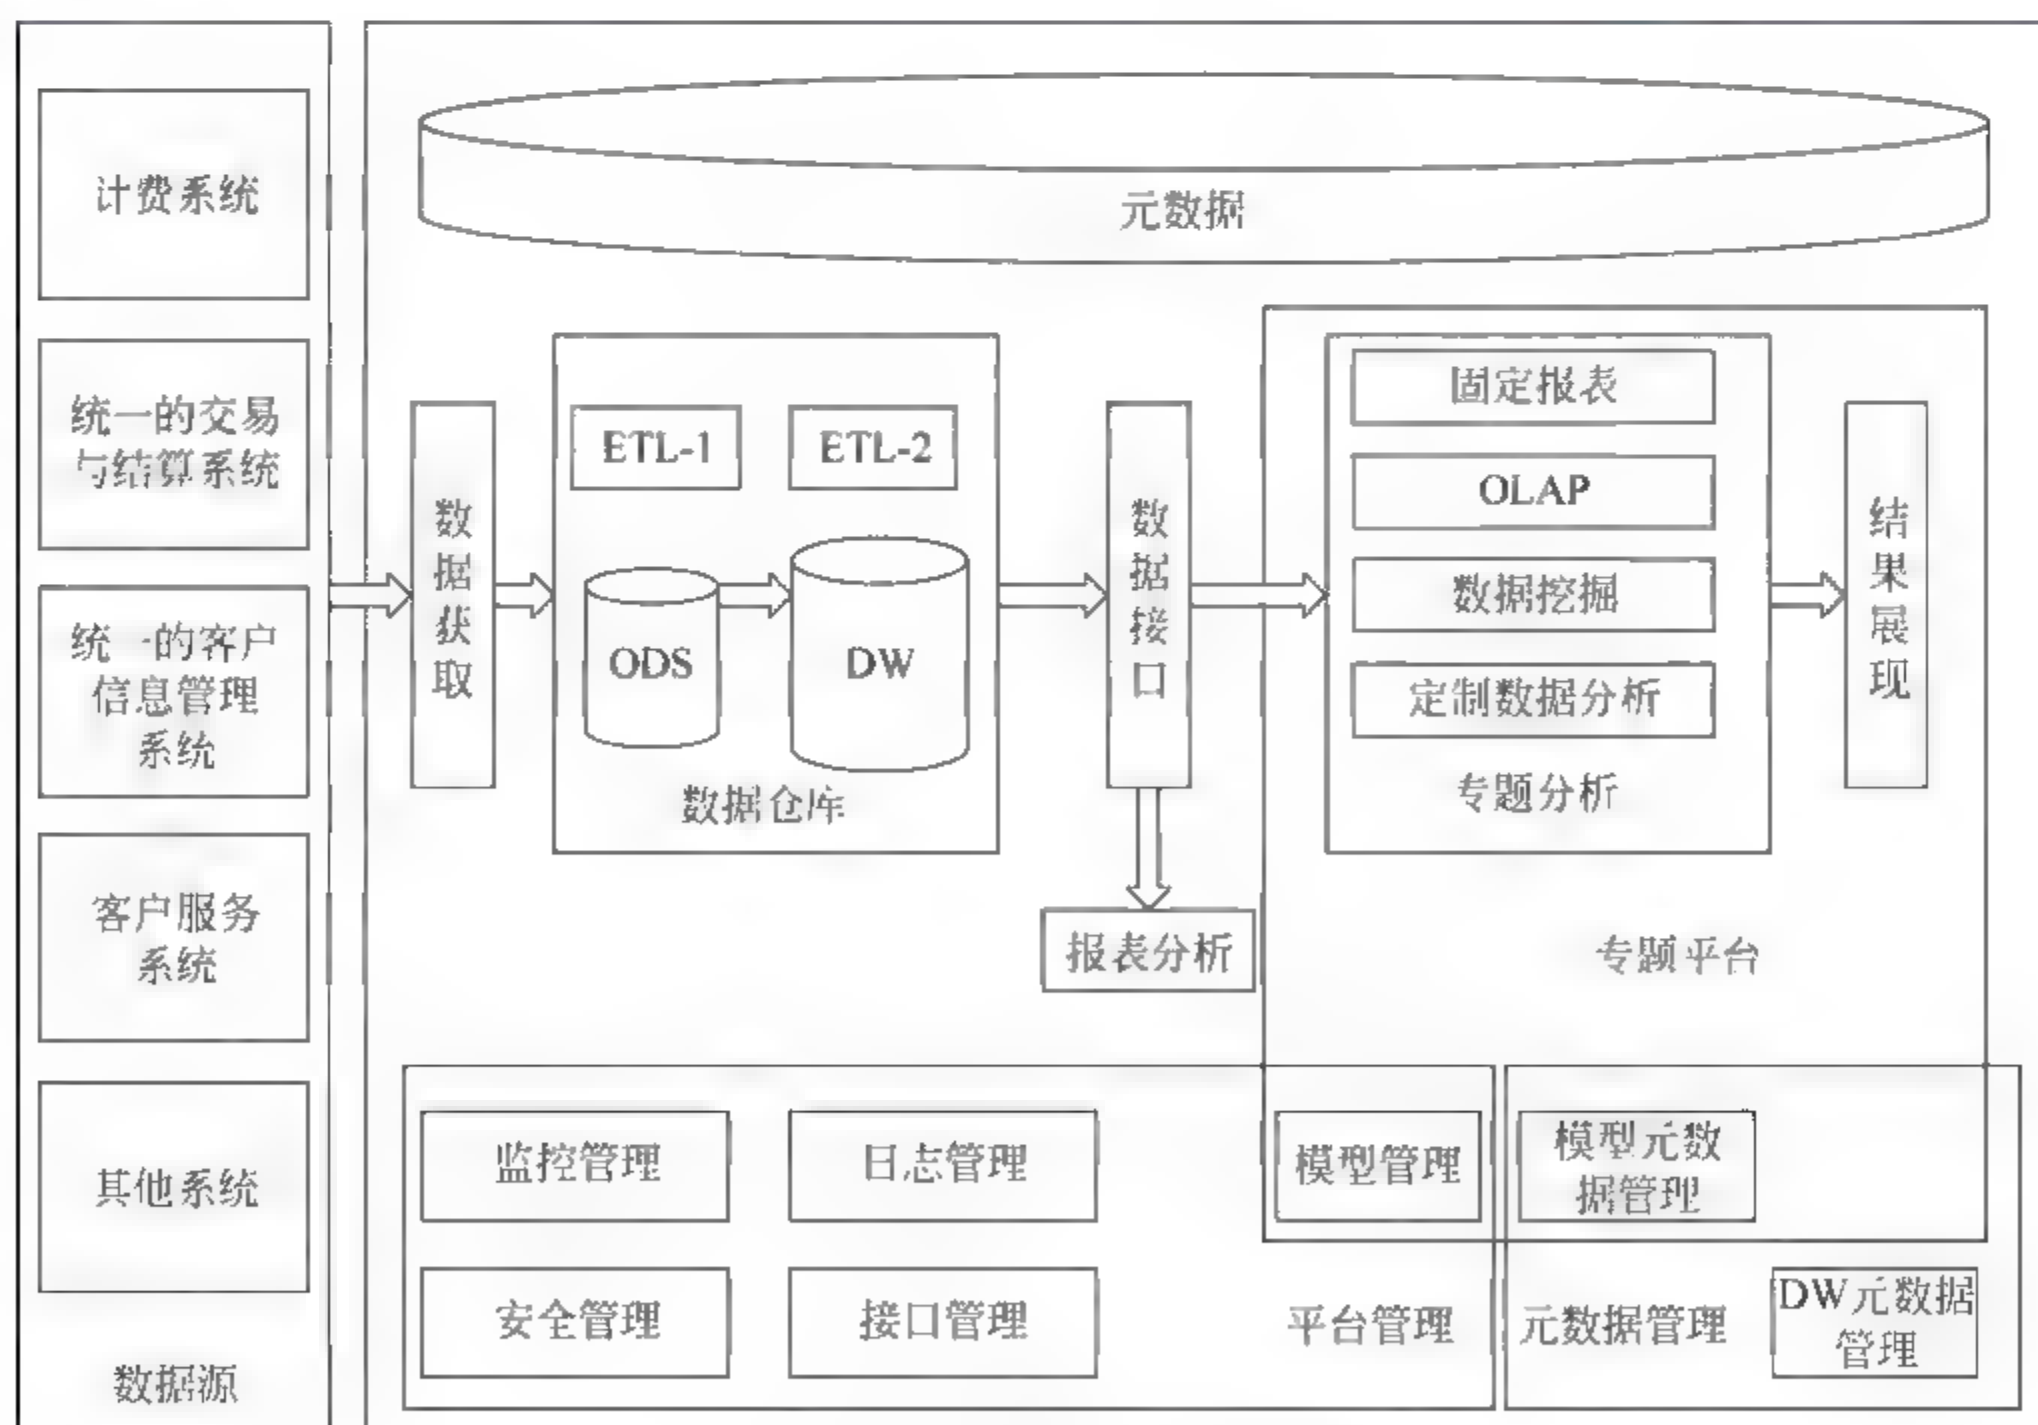


图 10.6 分析型 CRM 示意图

### 3) 协作型 CRM(Collaborative CRM)

协作型 CRM 可以实现全方位的客户交互服务和收集客户信息,实现多种客户交流渠道(如呼叫中心、面对面交流、网上交流、E-mail、Fax 等)的集成,使各种渠道相互融合,保证企业和客户都能获得完整、准确和一致的信息。其中:

- (1) 电话接口(telephone interface)提供与电话系统集成的接口,支持 CTI 中间件。
- (2) 电子邮件和传真接口。
  - 与电子邮件和传真集成,收发电子邮件和传真。
  - 自动产生电子邮件以及确认信息接收。
  - 存储活动关键特性,如电子邮件/传真类型、电子邮件/传真发送状态、发送日期时间等。
- (3) 网上互动交流。
  - 互动浏览
  - 个性化网页
  - 站点调查
  - 客户历史
  - 通过网络提交服务申请
- (4) 呼出功能支持电话销售/电话市场推广等。

除了 CRM,ERP(Enterprise Resource Planning,企业资源规划)也是一种企业运行管理软件,其侧重点是对企业内部业务流程以及企业资源进行管理。

在 ERP 刚刚被引入国内时,许多人将其看做是提高企业运营水平的万能钥匙,并期望它能给各行业带来革命性的变革,而结果却差强人意。其主要原因是没有真正理解 ERP 的实质,即没有摆正其在企业管理中的位置。

ERP 作为一种企业资源管理的后台软件,解决的是企业内部各环节的协调问题,如财务、生产、采购和仓储等部门间的协调关系。同样作为现代企业的管理软件,ERP 与 CRM 在企业运营过程中,处于不同的位置,担任不同的角色。前者面向后台,后者面向前台。一个保证企业生产出更高质量的产品,而另一个帮助企业理顺与客户的关系,向客户提供最好的服务。这是企业在激烈的市场竞争中立于不败之地不可或缺的两个环节。

事实上,在国际各大软件厂商的企业管理软件解决方案中,也往往是将两者紧密结合起来。对企业后台的财务、生产、采购和储运等部门而言,CRM 提供客户需求、市场分布、对产品的反应及产品销售状况等信息,通过 CRM 与企业后台 ERP 的集成,CRM 提供的丰富数据和智能化分析结果,成为企业经营决策的科学依据。

通过 ERP 与 CRM 系统的紧密集成,把企业供应商和服务商等联成一个有机的整体,真正实现以客户为中心,并最大限度地满足客户需要和降低企业成本。

## 10.2 客户细分

在过去国内电信市场竞争相对平缓的环境下,传统的大众化营销模式是成功的,为企业带来了数量庞大的客户群和巨大的经济和社会效益。但随着市场竞争环境的不断演变,竞争越来越白热化,电信产品越来越丰富,价格战不断升级,尤其是面向中高端客户采用传统



的大众化营销模式已经不能达到预期目标,无法满足新的市场需求。在这种形势下,需要探索一种有别于传统大众化的更有效的新型营销模式,有针对性地吸引长期、稳定且优质的客户群,以达到更高的产品投资回报率,提高市场占有率,为电信企业创造更高的价值和利润,因此客户细分应运而生。客户细分是在充分了解客户的基础上,通过客户使用行为特征、消费行为特征和自然属性等,区分不同的客户群,以实现针对性营销。

### 10.2.1 客户生命周期

客户生命周期(又称客户关系生命周期)是指客户关系水平随时间变化的发展轨迹,即从一个客户开始对企业进行了解或企业欲发展某一客户开始,直到客户与企业的业务关系完全终止且与之相关的事宜完全处理完毕的时间间隔。它直观地揭示了客户关系发展从一种状态向另一种状态迁移的特征。客户生命周期是企业产品生命周期的演变。对企业而言,客户生命周期要比企业某个产品的生命周期更为重要。

根据电信行业客户关系的特点,其客户生命周期可分为五个阶段,分别是识别期,即客户关系的建立阶段;成长期,即客户关系的加强阶段;稳定期,即客户关系的维持稳定阶段;预警期,即客户关系的挽留阶段;离网期,即客户关系的破裂或恢复阶段,如图 10.7 所示。




图 10.7 电信客户生命周期

对于客户生命周期的不同阶段,客户价值与企业的投入都大不相同,企业采取的策略也有所不同。识别期企业需要主动地发现可能建立客户关系的潜在客户,从广大消费群体中挖掘目标客户;成长期企业需要甄别客户类型,挖掘有价值客户,采取客户关系提升策略;稳定期企业需要维系客户关系;预警期企业需要发现衰退迹象,判断客户关系是否值得保持,采取挽留或终止策略;离网期企业需要采取客户关系恢复策略。在明确客户生命周期的基础上,电信运营商需要对客户进行全生命周期管理。客户全生命周期管理是指在假设企业具备生产有市场潜力的产品和服务能力的情况下,如何从广大消费群体中发现目标客户,以及围绕目标客户关系的建立、发展、成熟和衰退这一生命周期,根据客户关系所处的不同阶段,采用相应的组合策略,对目标客户资源进行动态管理,以期实现企业和客户长期的



价值互动,最大化长期互动关系的效用,达到客户与企业的双赢。客户全生命周期管理开始于企业潜在客户的识别,终止于企业与客户关系的破裂。

客户生命周期可以根据客户使用行为、消费行为和客户价值等几大类指标进行划分。

通过对客户特征全面而深入的分析,细分潜在的客户群,进一步洞察客户诉求,采用特定的营销手段吸引客户注意,使客户知晓企业及企业提供的产品或服务。在持续认知的基础上,客户开始考虑是否使用该企业的产品或服务满足自身需求。通过对产品的综合评价,客户决定是购买该企业的产品或服务,还是购买竞争对手的产品或服务。一旦客户决定购买该企业的产品或服务,实现了第一次购买,潜在客户就成为实际客户。如果运营商能实现有效的维系,鼓励存量客户购买数量更多的产品、价值更高的服务,客户不断地选择购买该企业的产品和服务,则客户关系得以长期延续。一旦发现客户对该企业的感知度或价值水平下跌而可能流失,则实施有效的挽留,以降低因有价值的客户不再光顾而产生的流失;同时可以终止没有盈利能力的、停止发展的或者不令人满意的客户关系,取而代之的是能够更好地与企业的利润、成长和定位相匹配的客户。

针对电信客户生命周期各阶段的不同特点,运营商可以采取不同的策略预防和控制客户流失,如表 10.1 所示。

表 10.1 电信客户生命周期不同阶段的客户维系挽留策略

客户生命周期阶段	成 长 期	稳 定 期	预 警 期
策略	提升客户价值 长远规划营销方案 市场区隔	提高客户满意度 设置转网壁垒 老客户回报	流失预警 欠费管理 带号转资费

10.2.2 客户价值

客户价值是近年来营销领域研究的热点和难点之一。营销科学研究所(Marketing Science Institute)已经连续几年将客户价值列为优先研究领域。对于客户价值的研究可以从三方面展开,即客户为价值感受主体、企业为价值感受主体以及企业与客户互为价值感受主体和感受客体。

从企业的角度研究客户价值,主要包括两个方面,即客户价值和客户终生价值(Customer Lifetime Value,CLV)。客户价值是指客户当前所产生的净利润。客户终生价值的定义有多种,其中 1985 年 Barbara Jackson 将客户终生价值定义为客户当前以及将来所产生的货币利益的净现值;1994 年 Jackson 将客户终身价值定义为企业预计客户在长期的购买行为中,会对该企业带来未来利润的总现值;Bitran 和 Mondschein 认为客户终生价值是客户在整个生命周期内所产生的净利润的折现值。综上所述,客户终生价值可定义为客户在整个生命周期内各个交易期的利润净现值之和。客户终生价值是企业利润的重要来源,客户终生价值越大,对于企业长远发展越有利。

由客户价值和客户终生价值的定义可知,前者关注客户在某一时间点上的价值表现;后者关注客户在整个客户生命周期的最终价值贡献。随着对客户终生价值研究的深入,很自然地将客户终生价值和客户生命周期两者紧密联系起来。客户生命周期中稳定期越长,客户价值折现年限越长,客户价值越高。



下面介绍客户价值计算。

客户价值的含义可以从客户和企业两个方面分析。从客户的角度而言,客户价值是指客户感知价值,可利用 1995 年纽曼提出的客户价值特性/成本模型加以说明,如图 10.8 所示。

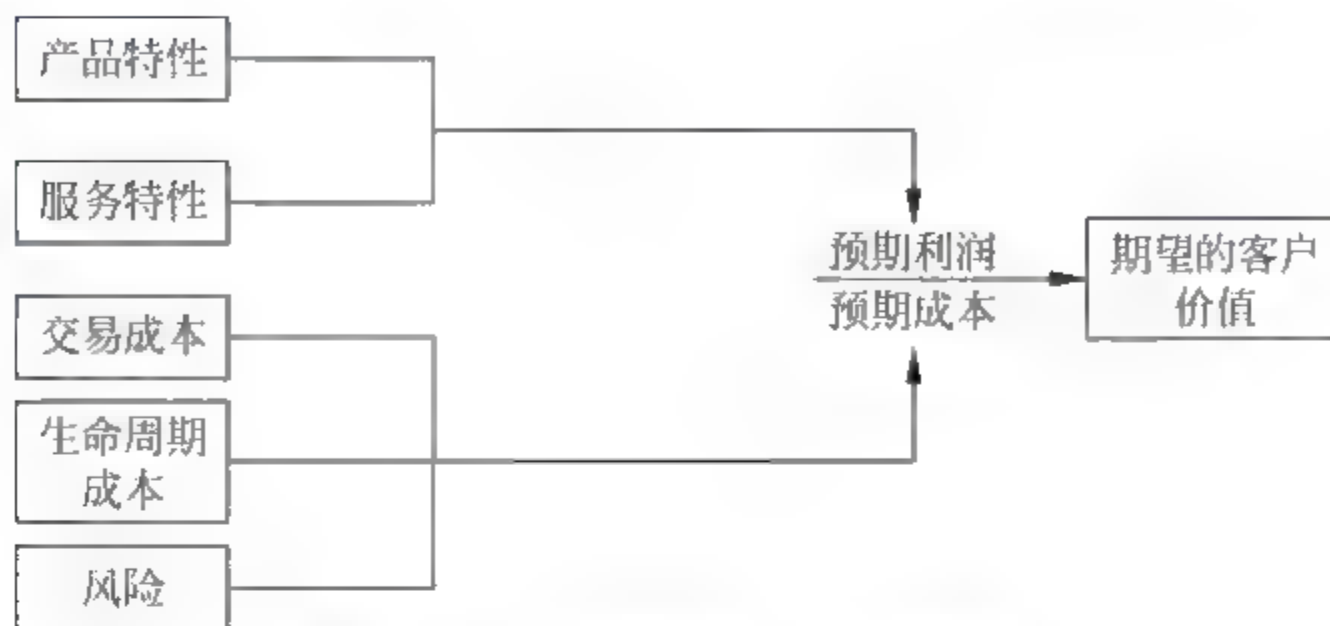


图 10.8 客户价值特性/成本模型

从电信企业的角度而言,客户价值是指客户终生价值,通常由历史价值、当前价值和潜在价值三部分构成,如图 10.9 所示。历史价值是指到目前为止已经实现的客户价值;当前价值是指如果客户当前行为模式不发生改变的话,在将来会给企业带来的客户价值;潜在价值是指如果企业通过有效的交叉销售、调动客户购买积极性或客户向别人推荐产品和服务等,从而可能增加的客户价值。

企业在评价客户是否具有价值时,不仅要参考客户历史价值的表现,更重要的是预测其当前价值和潜在价值的表现。客户历史价值是指已经带来的利润,是企业感知客户价值的一个重要方面;客户当前价值决定了企业当前的盈利水平;客户潜在价值关系到企业的长远利润,是直接影响企业是否继续投资于该客户的一个重要因素。

根据客户终生价值的定义,1995 年 Angus Jenkison 给出其通用的计算公式,即:

$$V = \sum_{n=0}^T (R_n - C_n) \times (1+i)^{-n} \quad (10.1)$$

其中, $T$  为客户的生命周期, $R_n$  为客户在第  $n$  年给企业带来的收益(包括货币因素和非货币因素), $C_n$  为企业为其投入的成本, $i$  为银行贴现率。对于客户终生价值的计算,企业可变的投入成本是影响客户终生价值的重要变量,而客户生命周期时间是一个关键参数。

对于历史价值、当前价值和潜在价值都可以通过直接计算和指标评价两种方法得到。直接计算是指通过严格的数学计算得到具体数值;指标评价是指通过相关指标的评价间接获得评价值。

参照客户终生价值并结合电信客户自身特点给出了一种客户历史价值、当前价值、潜在价值和总体价值的计算方法,分别如式(10.2)~式(10.5)所示。

客户历史价值:

$$V_h = R(t) \times \text{ARPU} - C_i - C_p \quad (10.2)$$

其中, $R(t)$  是客户在网时长, $C_i$  是均摊成本, $C_p$  是个人维系成本。

客户当前价值:

$$V_c = F_3 \times (F_3/\text{ARPU}) \times K \times B \quad (10.3)$$

其中,  $F_3$  是最近三个月应缴费用总额;  $K$  为价值成色, 是本地通话与长途和漫游话费的比值, 反映话务结构和结算成本;  $B$  为价值爆发力, 是最近五个月最高 ARPU 值与 ARPU 均值的比值。

客户潜在价值:

$$V_p = \sum (\text{ARPU} \times (1 - L(t)) + M) \tag{10.4}$$

其中,  $L(t)$  是客户在未来第  $t$  个月的流失概率,  $M$  是客户的协议剩余金额。

客户总体价值:

$$V = 0.25 \times (V_h - V_{havg}) / \text{SD}(V_h) + 0.5 \times (V_c - V_{cavg}) / \text{SD}(V_c) + 0.25 \times (V_p - V_{pavg}) / \text{SD}(V_p) \tag{10.5}$$

客户总体价值是客户历史、当前和潜在价值标准化后的加权平均, 其中  $V_{havg}$ 、 $V_{cavg}$  和  $V_{pavg}$  分别是客户历史价值、当前价值和潜在价值的均值;  $\text{SD}(V_h)$ 、 $\text{SD}(V_c)$  和  $\text{SD}(V_p)$  分别是客户历史价值、当前价值和潜在价值的标准差。

10.2.3 数据准备

为了维系挽留即将到期的 CDMA 合约用户, 针对不同客户群的特征实施客户细分, 并结合电信企业市场部门的营销策略提供个性化服务, 减少客户流失。本例选取某市 2007 年 6~8 月即将到期的 CDMA 合约用户资料, 以及最近连续六个月的通话详单和出账费用等相关数据作为分析对象, 如表 10.2 所示。

表 10.2 某市 2007 年 6~8 月即将到期的 CDMA 合约用户一览表

合约到期的期限	用户数	
	在网	正常出账
2007/06	745	238
2007/07	1545	1078
2007/08	6135	3934
合计	8425	5250

由表 10.2 可知, 2007 年 6~8 月即将到期的在网 CDMA 合约用户数共计 8425, 正常出账的用户数 5250。对于这部分用户还需要进行数据清洗, 以剔除下列无效用户, 即:

- (1) 去除入网渠道为“员工”的记录, 因为内部员工并非分析的对象, 属于噪声数据。
- (2) 去除孤立点。在进行客户价值聚类时, 发现“平均当月总消费”为 1073 元、1060 元和 956 元的三个用户记录使得聚类中心发生严重偏移, 去除其中个别的孤立点。在进行消费行为聚类时, 发现“平均套餐优惠费”中存在超大值, 去除其中个别的孤立点。
- (3) 检测某项消费额为负值的用户, 无此类记录存在, 应去除。
- (4) 在进行消费行为聚类的变量选择时, 由于漫游一项只有漫游计费次数, 而其他是以通话次数来衡量, 随机抽取 20% 的数据验证平均长途通话次数与平均长途计费次数大致呈正比关系, 因此把漫游计费次数也作为聚类分析的一个变量。

去除上述“噪声”后, 针对 2007 年 6~8 月即将到期的有效的 CDMA 合约用户 4824 进



行客户细分,并采用 Z Score 方法进行数据标准化。

#### 10.2.4 分析过程

下面介绍客户细分过程。

(1) 利用 K-means 聚类算法,根据客户价值聚类为高端、中高端、中端和低端四类客户群,如表 10.3 所示。

表 10.3 根据客户价值聚类的结果

类别	客户价值/元	出账费用明细			用户数	特征描述
高端用户	565.39	主要费用项	金额/元	占比	108	以漫游为主
		漫游费	267.37	47.3%		
		本地话费	234.89	41.5%		
		长途话费	37.94	6.7%		
		增值费	13.99	2.5%		
		短信费	11.2	2%		
中高端客户	279.96	主要费用项	金额/元	占比	569	以市话和漫游为主
		本地话费	132.95	47.5%		
		漫游费	101.97	36.4%		
		长途话费	24.43	8.7%		
		增值费	12.64	4.5%		
		短信费	7.97	2.9%		
中端客户	145.69	主要费用项	金额/元	占比	541	以市话和漫游为主
		本地话费	71.76	49.3%		
		漫游费	47.43	32.6%		
		长途话费	12.47	8.6%		
		增值费	8.75	6%		
		短信费	5.28	3.5%		
低端客户	29.94	主要费用项	金额/元	占比	3606	以市话和短信为主
		本地话费	15.69	52.4%		
		短信费	4.53	15.1%		
		增值费	3.73	12.5%		
		长途话费	3.55	11.9%		
		漫游费	2.44	8.1%		
合计	4824					

由图 10.9 可以看出聚类效果较为显著,绝大多数很集中,不存在极值,只有个别的孤立点,且它们距离聚类中心并不远。

(2) 利用 K means 聚类算法,根据客户消费行为,如月均基本通话费、月均长途费、月均漫游费、月均短信费和月均增值费等指标聚类为节约型、时尚型、电话型、长途型、短信型和未知型六类客户群,如表 10.4 和图 10.10 所示。




图 10.9 四种客户群的客户价值分布




图 10.10 根据客户消费行为聚类的结果



表 10.4 根据客户消费行为聚类的结果

序 号	类 别 名 称	用 户 数
1	节约型	3703
2	时尚型(以增值、长途、漫游为主)	20
3	电话型(以市话、长途、漫游为主)	395
4	长途型	189
5	短信型	185
6	未知型(其他费用高)	332
合计		4824

(3) 利用 K-means 聚类算法,根据客户通话行为特征,如平均本地通话次数、平均主叫通话次数、平均被叫通话次数、平均长途通话次数、平均 IP 通话次数、平均漫游计费次数和平均假期通话次数等指标聚类为极少型、假期型、长途漫游型、普通型和 IP 电话型五类客户群,如表 10.5 和图 10.11 所示。




图 10.11 根据客户通话行为聚类的结果

表 10.5 根据客户通话行为聚类的结果

序号	类别名称	用户数
1	极少型	3561
2	假期型	114
3	长途漫游型	249
4	普通型	806
5	IP 电话型	94
合计	4824	

(4) 汇总上述聚类结果,如表 10.6 所示。电信企业市场营销部门可以根据不同客户群的价值贡献、消费行为特征和通话行为特征推荐适合的优惠套餐,实现个性化维挽服务。

表 10.6 聚类结果的汇总

客户价值	消费行为		通 话 行 为					合计
			极少型	假期型	长途漫 游型	普通型	IP 电话型	
低 端 用 户	节约型	用户数	2999	1	0	352	19	3371
		消费行为占比	89.0%	0.0%	0.0%	10.4%	0.6%	100.0%
		通话行为占比	93.7%	100.0%	0.0%	91.7%	95.0%	
		总占比	83.2%	0.0%	0.0%	9.8%	0.5%	93.5%
	短信型	用户数	202	0	0	32	1	235
		消费行为占比	86.0%	0.0%	0.0%	13.6%	0.4%	100.0%
		通话行为占比	6.3%	0.0%	0.0%	8.3%	5.0%	
		总占比	5.6%	0.0%	0.0%	0.9%	0.0%	6.5%
	合计	用户数	3201	1	0	384	20	3606
		消费行为占比	88.8%	0.0%	0.0%	10.6%	0.6%	100.0%
		通话行为占比	100.0%	100.0%	0.0%	100.0%	100.0%	
		总占比	88.8%	0.0%	0.0%	10.6%	0.6%	100.0%
中 高 端 用 户	节约型	用户数	2	1	6	3	3	15
		消费行为占比	13.3%	6.7%	40.0%	20.0%	20.0%	100.0%
		通话行为占比	1.6%	2.1%	3.5%	1.6%	7.9%	
		总占比	0.4%	0.2%	1.1%	0.5%	0.5%	2.7%
	时尚型 (增值漫游 长途)	用户数	4	0	5	2	0	11
		消费行为占比	36.4%	0.0%	45.4%	18.2%	0.0%	100.0%
		通话行为占比	3.3%	0.0%	2.9%	1.0%	0.0%	
		总占比	0.7%	0.0%	0.9%	0.4%	0.0%	2.0%
	电话型 (市话漫游 长途)	用户数	9	21	126	79	21	256
		消费行为占比	3.5%	8.2%	49.2%	30.9%	8.2%	100.0%
		通话行为占比	7.4%	43.7%	74.1%	41.4%	55.2%	
		总占比	1.6%	3.7%	22.1%	13.9%	3.7%	45.0%
	长途型	用户数	24	25	1	72	4	126
		消费行为占比	19.1%	19.8%	0.8%	57.1%	3.2%	100.0%
		通话行为占比	19.7%	52.1%	0.6%	37.7%	10.5%	
		总占比	4.2%	4.4%	0.2%	12.7%	0.7%	22.2%



续表

客户价值	消费行为		通 话 行 为					合计
			极少型	假期型	长途漫游型	普通型	IP 电话型	
中高端用户	未知型 (其他费用高)	用户数	81	0	27	32	5	145
		消费行为占比	55.9%	0.0%	18.6%	22.1%	3.4%	100.0%
		通话行为占比	66.4%	0.0%	15.9%	16.7%	13.2%	
		总占比	14.2%	0.0%	4.7%	5.6%	0.9%	25.4%
	短信型	用户数	2	1	5	3	5	16
		消费行为占比	12.5%	6.2%	31.3%	18.7%	31.3%	100.0%
		通话行为占比	1.6%	2.1%	3.0%	1.6%	13.2%	
		总占比	0.4%	0.2%	0.9%	0.5%	0.9%	2.9%
	合计	用户数	122	48	170	191	38	569
		消费行为占比	21.4%	8.4%	29.9%	33.6%	6.7%	100.0%
		通话行为占比	100.0%	100.0%	100.0%	100.0%	100.0%	
		总占比	21.4%	8.4%	29.9%	33.6%	6.7%	100.0%
高端用户	时尚型(增值漫游长途)	用户数	1	2	5	0	0	8
		消费行为占比	12.5%	25.0%	62.5%	0.0%	0.0%	100.0%
		通话行为占比	33.3%	4.3%	10.6%	0.0%	0.0%	
		总占比	0.9%	1.9%	4.6%	0.0%	0.0%	7.4%
	电话型(市话漫游长途)	用户数	0	37	34	4	1	76
		消费行为占比	0.0%	48.7%	44.7%	5.3%	1.3%	100.0%
		通话行为占比	0.0%	78.7%	72.3%	44.4%	50.0%	
		总占比	0.0%	34.3%	31.5%	3.7%	0.9%	70.4%
	长途型	用户数	2	8	3	4	0	17
		消费行为占比	11.8%	47.1%	17.6%	23.5%	0.0%	100.0%
		通话行为占比	66.7%	17.0%	6.4%	44.4%	0.0%	
		总占比	1.9%	7.4%	2.8%	3.7%	0.0%	15.8%
	未知型 (其他费用高)	用户数	0	0	4	0	1	5
		消费行为占比	0.0%	0.0%	80.0%	0.0%	20.0%	100.0%
		通话行为占比	0.0%	0.0%	8.5%	0.0%	50.0%	
		总占比	0.0%	0.0%	3.7%	0.0%	0.9%	4.6%
	短信型	用户数	0	0	1	1	0	2
		消费行为占比	0.0%	0.0%	50.0%	50.0%	0.0%	100.0%
		通话行为占比	0.0%	0.0%	2.1%	11.1%	0.0%	
		总占比	0.0%	0.0%	0.9%	0.9%	0.0%	1.8%
	合计	用户数	3	47	47	9	2	108
		消费行为占比	2.8%	43.5%	43.5%	8.3%	1.9%	100.0%
		通话行为占比	100.0%	100.0%	100.0%	100.0%	100.0%	
		总占比	2.8%	43.5%	43.5%	8.3%	1.9%	100.0%

10.2.5 结果

由上述客户细分可知,低端用户群的消费类型主要集中在节约型(93.5%)和短信型(6.5%)两种;通话行为类型主要集中在极少型(88.8%)和普通型(10.6%)。且其中绝大部分的用户既是节约型又是极少型(83.2%),此外还有 9.8%的用户非常节约,基本限于本地通话;还有 5.6%的用户使用短信。

中端用户群的节约型和普通型占比最大,短信一族次之。从消费行为特征上看,节约型占比 58.6%,短信型占比 15.6%;从通话行为特征上看,极少型和普通型分别占 44%和 41.4%。

中高端用户群的消费行为和通话行为较为分散,多数以市话、长途和漫游通话为主。

高端用户群的市话、长途、漫游费用占比很高。从消费行为特征上看,电话型占比 70.4%,而长途型只占 15.8%;从通话行为特征上看,假期型和长途漫游型各占 43.5%,因此高端用户群的主要价值来源于漫游和长途业务,且在假期客户价值尤其高。

由表 10.7 可知,节约型与极少型用户几乎一一对应,包含了少量的普通型;时尚型用户除了长途和漫游费用较高外,还有很大一部分增值业务的费用,这部分用户数量不多,主要集中在长途漫游型;电话型用户,即市话、长途和漫游费用均很高的用户,集中在长途漫游型,还有一部分普通型用户;长途型用户有一半是普通型,还有少量的极少型和假期型用户;未知型用户其他费用极高,且用户数不少,60%的用户是极少型,据推测其他费用可能是使用了数字业务导致语音业务很少的用户反而其他费用高;短信型用户大部分来源于节约型,还有 20.8%的普通型,与实际情况相符。

表 10.7 根据客户消费行为和通话行为聚类的结果

消 费 行 为		通 话 行 为					合 计
		极少型	假期型	长途漫游型	普通型	IP 电话型	
节约型	用户数	3140	12	25	488	38	3703
	消费行为占比	84.8%	0.3%	0.7%	13.2%	1.0%	100.0%
	通话行为占比	88.2%	8.1%	10.0%	60.6%	39.1%	
	总占比	65.2%	0.2%	0.5%	10.2%	0.7%	76.8%
时尚型 (增值漫 游长途)	用户数	6	2	10	2	0	20
	消费行为占比	30.0%	10.0%	50.0%	10.0%	0.0%	100.0%
	通话行为占比	0.2%	1.8%	4.0%	0.2%	0.0%	
	总占比	0.1%	0.0%	0.2%	0.0%	0.0%	0.3%
电话型 (市话漫 游长途)	用户数	25	61	172	109	28	395
	消费行为占比	6.3%	15.4%	43.6%	27.6%	7.1%	100.0%
	通话行为占比	0.7%	55.0%	69.1%	13.5%	30.4%	
	总占比	0.5%	1.3%	3.6%	2.3%	0.6%	8.3%
长途型	用户数	39	37	4	104	5	189
	消费行为占比	20.6%	19.6%	2.1%	55.1%	2.6%	100.0%
	通话行为占比	1.1%	33.3%	1.6%	12.9%	5.4%	
	总占比	0.8%	0.8%	0.1%	2.2%	0.1%	4.0%



续表

消 费 行 为		通 话 行 为					合 计
		极少型	假期型	长途漫游型	普通型	IP 电话型	
未知型 (其他费用高)	用户数	111	0	32	34	8	185
	消费行为占比	60.0%	0.0%	17.3%	18.4%	4.3%	100.0%
	通话行为占比	3.1%	0.0%	12.9%	4.2%	8.7%	
	总占比	2.3%	0.0%	0.7%	0.7%	0.2%	3.9%
短信型	用户数	240	2	6	69	15	332
	消费行为占比	72.3%	0.6%	1.8%	20.8%	4.5%	100.0%
	通话行为占比	6.7%	1.8%	2.4%	8.5%	16.3%	
	总占比	5.0%	0.0%	0.1%	1.4%	0.3%	6.8%
合计	用户数	3561	114	249	806	94	4824
	消费行为占比	73.9%	2.3%	5.2%	16.7%	1.9%	100.0%
	通话行为占比	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
	总占比	73.9%	2.3%	5.2%	16.7%	1.9%	100.0%

从通话行为上看,极少型对应节约型,假期型对应时尚型和长途型,长途漫游型对应电话型,普通型对应节约型,IP 电话型对应电话型和节约型。

综上所述,某市 2007 年 6~8 月即将到期 CDMA 合约客户细分结果如表 10.8 所示。

表 10.8 某市 2007 年 6~8 月即将到期 CDMA 合约客户细分结果

序号	类 别 名 称	特征描述	用户数	营 销 策 略
1	节省型	短信量大,电话量少	3450	短信优惠
2	均衡型	被叫明显多于主叫,各业务费用均衡	737	被叫优惠,各种业务绑定优惠
3	长途型	长途费用高,几乎无漫游费用	189	长途优惠
4	市话长途漫游型	市话、长途、漫游费用均很高	209	市话、长途、漫游包月优惠及绑定优惠
5	增值长途漫游型	用户群小,增值费用高	20	可不考虑
6	假期型	假期时各项费用均很高	114	针对假期时段的综合优惠

此外,4824 用户中选择各种“校园套餐”的用户数为 2920,占 60.5%,他们大多数为低端客户,其通话行为特征表现为节省型,月均消费小于 50 元;选择各种“商旅套餐”的用户数为 1090,约占 22.6%,他们大多数为高端和中高端客户,其通话行为特征表现为市话长途漫游型或市话型,月均消费大于 370 元。这两类客户群在消费行为特征和通话行为特征方面差异较明显,占 83%以上。分析中还可看出漫游业务较多的用户长途业务也多,可针对市话长途漫游型和增值长途漫游型这两类客户群推出组合业务,或针对二者共同推出长途漫游绑定业务。

## 10.3 重入网识别

### 10.3.1 定义

重入网是指已经拥有或曾经拥有某一家电信运营商的一张 SIM(Subscriber Identify Module,客户识别模块)卡(又称用户识别卡)的情况下,重新在本地或本省其他地区购买新的同一运营商的 SIM 卡,新卡部分或者全部替代旧卡功能。

由于市场竞争日趋激烈,以及增量市场趋于饱和,重入网现象日趋严重,比例也越来越高。重入网造成的卡号资源浪费、欠费等后果直接导致运营商营销成本的增加和业务收入的下滑。因此,控制重入网比例,有效降低重入网带来的运营成本和风险,目前已经成为运营商面临的难题,重入网识别正是在这样的背景下应运而生,其应用价值在于为代理商佣金政策动态调整和绩效考核提供科学依据,提高维系挽留的精确度和维系成本使用的有效性。

### 10.3.2 数据准备

数据准备主要是选择合适的数据源,整理分析所需的各种数据,包括通话、消费、欠费和客服等数据,对原始数据进行检查和预处理,生成新的衍生变量,并整理出适合分析使用的数据宽表。一方面尽量确保数据的完整性;另一方面剔除冗余数据,减少噪声。

根据分析需求选取某市 2008 年 9 月流失的 CDMA 客户(45537 户)和 2008 年 9、10 月连续两个月新发展的 CDMA 用户(135638 户)作为分析对象。从 ODS 系统和业务支撑系统抽取其通话详单、客户资料和出账等数据,按照客户 ID 进行汇总和合并,生成一张数据宽表,其中每行代表一个客户,每列代表一个变量。数据宽表格式如表 10.9 所示。

表 10.9 数据宽表格式

类别	列 名 称	类 型	描 述
客户信息	CUST_ID	CHAR(20)	客户 ID
	GENDER	CHAR(1)	性别
	AGE	NUMERIC	年龄
	IS_LOC	CHAR(1)	是否本地居民
	NUM_OF_USERS	NUMERIC	客户对应的用户总数
	DATE	DATE	统计日期
用户信息	ACC_DATE	DATE	出账日期
	USER_ID	CHAR(15)	用户 ID
	PIN	CHAR(15)	号码
	VIP_TYPE	CHAR(2)	用户价值
	PAY_MODE	CHAR(2)	用户付费方式
	HANDSET_MODEL	CHAR(20)	用户手机类型
	MANUFACTURER	CHAR(20)	用户手机厂家



续表

类别	列 名 称	类 型	描 述
用户 信息	IMEI	CHAR(15)	用户手机 IMEI 串号
	COLLECT_MODE	CHAR(1)	催缴模式
	SVC_ID	CHAR(5)	业务类型
	INNET_LOC	CHAR(4)	入网地区
	DEPT_NO	CHAR(4)	部门编码
	INNET_CHANNEL	CHAR(1)	入网渠道
	SALE_TYPE	CHAR(2)	销售模式
	CALL_LOC	CHAR(4)	当前活动区域
	CALL_LOC_LST	CHAR(4)	上次活动区域
	INNET_AGE	NUMERIC	入网年龄
	INNET_DATE	DATE	入网日期
	Tenure_IN_M	NUMERIC	在网时长(月)
	ARPU	NUMERIC	ARPU
	MOU	NUMERIC	MOU
	ARPM	NUMERIC	ARPM
资费 信息	PLAN_INIT	CHAR(5)	初始套餐
	PLAN_LAST	CHAR(5)	最近套餐
	PLAN_CURR	CHAR(5)	当前套餐
	PLAN_CHG_CNT	NUMERIC	套餐变动总数
	CONS_DUE_DATE	DATE	当前承诺到期日
	IS_CONS_OVER	CHAR(1)	是否已经承诺到期
	IS_CONS_DUE	CHAR(1)	是否当月承诺到期
	CONS_TYPE	CHAR(3)	承诺类型
	CONS_CHG	NUMERIC	是否有承诺话费
	HANDSET_FREE	CHAR(20)	承诺是否赠送手机
	HANDSET_PRICE	NUMERIC	承诺赠送手机价值
	DINNER_SPEC	CHAR(5)	特服套餐
	RENT_PACKAGE	NUMERIC	套餐租费
	IS_OVR_LMT	CHAR(1)	是否超过资费套餐定量
	RAT_OVR_LMT	NUMERIC	超过资费套餐定量部分与定量的比例
	TIME_TO_LST_PLN	NUMERIC	距最近一次套餐变更的时间
	PLAN_PRICE	CHAR(1)	套餐价位
	VOC_PACKAGE	NUMERIC	包月话费
	VAS PACKAGE	NUMERIC	包月特服
	SMS_PACKAGE	NUMERIC	包月短信
	PLAN_UTIL	NUMERIC	套餐使用度(针对定额或包月套餐)
	AVG_SMS_CHG	NUMERIC	平均每条短信费用
	AVG_PEAK_CALL_CHG	NUMERIC	平均每分钟忙时呼出费用

续表

类别	列 名 称	类 型	描 述
资费 信息	AVG_OFPK_CALL_CHG	NUMERIC	平均每分钟闲时呼出费用
	AVG_PEAK_CALL_CHG	NUMERIC	平均每分钟忙时呼入费用
	AVG_OFPK_CALL_CHG	NUMERIC	平均每分钟闲时呼入费用
	IS_COMP_PLAN	CHAR(1)	套餐是否针对竞争对手推出
	IS_LV_PLAN	CHAR(1)	套餐是否针对低端人群
	IS_HV_PLAN	CHAR(1)	套餐是否针对高端人群
	IS_LD_PLAN	CHAR(1)	套餐是否针对长途业务优惠
	IS_RM_PLAN	CHAR(1)	套餐是否针对漫游业务优惠
	IS_IN_PLAN	CHAR(1)	套餐是否针对接听优惠
	IS_SMS_PLAN	CHAR(1)	套餐是否针对短信优惠
	IS_VAS_PLAN	CHAR(1)	套餐是否针对增值服务优惠
	HANDSET_BIND	CHAR(20)	套餐是否绑定话机
账户 信息	PAY_TYPE	CHAR(2)	缴费渠道
	STATUS_CODE	CHAR(3)	账户状态
	DUE_CHARGE	NUMERIC	当月应缴金额
	CROSS_CHG	NUMERIC	结算费用总额
	ACT_PAID	NUMERIC	当月实缴金额
	RENT_FEE	NUMERIC	租费
	MOBILE_FEE	NUMERIC	本地通话费
	LONG_FEE	NUMERIC	本地国内长途费
	INTLONG_FEE	NUMERIC	本地国际长途费
	ROAM_FEE	NUMERIC	漫游费
	ROAM_INTLONG_FEE	NUMERIC	漫游国际长途费
	ROAM_LONG_FEE	NUMERIC	漫游国内长途费
	DATA_FEE	NUMERIC	数据业务费
	INCREMENT_FEE	NUMERIC	增值业务费
	SMS_FEE	NUMERIC	点对点短信费
	SPECIAL_FEE	NUMERIC	特服业务费
	MON_FEE	NUMERIC	包月费
	OTHER_FEE	NUMERIC	其他费
	SP_FEE	NUMERIC	SP 业务费
	CONSENT_FEE	NUMERIC	最低承诺应收费
	DELQ_CNT_CURR	NUMERIC	本次欠费持续时间
	DELQ_AMT_CURR	NUMERIC	本次欠费总额
行为 信息	AVG_PAY	NUMERIC	月均缴费额
	TOTAL_PAY	NUMERIC	缴费总额
	DELQ_CNT_EVER	NUMERIC	累计欠费次数
	DELQ_HALT_CNT_EVER	NUMERIC	累计欠费停机次数



续表

类别	列 名 称	类 型	描 述
行为 信息	CALL_LENGTH	NUMERIC	通话时长
	CALL_CNT	NUMERIC	通话次数
	CALL_CHG	NUMERIC	通话费用
	FREE_LENGTH	NUMERIC	免费通话时长
	FREE_CNT	NUMERIC	免费通话次数
	IN_CALL_LENGTH	NUMERIC	呼入通话时长
	IN_CALL_CNT	NUMERIC	呼入通话次数
	IN_CALL_CHG	NUMERIC	呼入通话费用
	OUT_CALL_LENGTH	NUMERIC	呼出通话时长
	OUT_CALL_CNT	NUMERIC	呼出通话次数
	OUT_CALL_CHG	NUMERIC	呼出通话费用
	IN_FREE_LENGTH	NUMERIC	呼入免费通话时长
	IN_FREE_CNT	NUMERIC	呼入免费通话次数
	OUT_FREE_LENGTH	NUMERIC	呼出免费通话时长
	OUT_FREE_CNT	NUMERIC	呼出免费通话次数
	IN_PK_CALL_LENGTH	NUMERIC	忙时呼入通话时长
	IN_PK_CALL_CNT	NUMERIC	忙时呼入通话次数
	IN_PK_CALL_CHG	NUMERIC	忙时呼入通话费用
	OUT_PK_CALL_LENGTH	NUMERIC	忙时呼出通话时长
	OUT_PK_CALL_CNT	NUMERIC	忙时呼出通话次数
	OUT_PK_CALL_CHG	NUMERIC	忙时呼出通话费用
	IN_OP_CALL_LENGTH	NUMERIC	闲时呼入通话时长
	IN_OP_CALL_CNT	NUMERIC	闲时呼入通话次数
	IN_OP_CALL_CHG	NUMERIC	闲时呼入通话费用
	OUT_OP_CALL_LENGTH	NUMERIC	闲时呼出通话时长
	OUT_OP_CALL_CNT	NUMERIC	闲时呼出通话次数
	OUT_OP_CALL_CHG	NUMERIC	闲时呼出通话费用
	PK_CALL_LENGTH	NUMERIC	忙时通话时长
	PK_CALL_CNT	NUMERIC	忙时通话次数
	PK_CALL_CHG	NUMERIC	忙时通话费用
	OP_CALL_LENGTH	NUMERIC	闲时通话时长
	OP_CALL_CNT	NUMERIC	闲时通话次数
	OP_CALL_CHG	NUMERIC	闲时通话费用
	PK_FREE_LENGTH	NUMERIC	忙时免费通话时长

续表

类别	列 名 称	类 型	描 述
行为 信息	PK_FREE_CNT	NUMERIC	忙时免费通话次数
	OP_FREE_LENGTH	NUMERIC	闲时免费通话时长
	OP_FREE_CNT	NUMERIC	闲时免费通话次数
	WK_CALL_LENGTH	NUMERIC	平时通话时长
	WK_CALL_CNT	NUMERIC	平时通话次数
	WK_CALL_CHG	NUMERIC	平时通话费用
	HL_CALL_LENGTH	NUMERIC	假日通话时长
	HL_CALL_CNT	NUMERIC	假日通话次数
	HL_CALL_CHG	NUMERIC	假日通话费用
	LOC_CALL_LENGTH	NUMERIC	区内通话时长
	LOC_CALL_CNT	NUMERIC	区内通话次数
	LOC_CALL_CHG	NUMERIC	区内通话费用
	DD_CALL_LENGTH	NUMERIC	国内长途通话时长
	DD_CALL_CNT	NUMERIC	国内长途通话次数
	DD_CALL_CHG	NUMERIC	国内长途通话费用
	IDD_CALL_LENGTH	NUMERIC	国际长途通话时长
	IDD_CALL_CNT	NUMERIC	国际长途通话次数
	IDD_CALL_CHG	NUMERIC	国际长途通话费用
	DD_PK_CALL_LENGTH	NUMERIC	国内长途忙时通话时长
	DD_PK_CALL_CNT	NUMERIC	国内长途忙时通话次数
	DD_OP_CALL_LENGTH	NUMERIC	国内长途闲时通话时长
	DD_OP_CALL_CNT	NUMERIC	国内长途闲时通话次数
	DD_WK_CALL_LENGTH	NUMERIC	国内长途平时通话时长
	DD_WK_CALL_CNT	NUMERIC	国内长途平时通话次数
	DD_HL_CALL_LENGTH	NUMERIC	国内长途假日通话时长
	DD_HL_CALL_CNT	NUMERIC	国内长途假日通话次数
	IDD_PK_CALL_LENGTH	NUMERIC	国际长途忙时通话时长
	IDD_PK_CALL_CNT	NUMERIC	国际长途忙时通话次数
	IDD_OP_CALL_LENGTH	NUMERIC	国际长途闲时通话时长
	IDD_OP_CALL_CNT	NUMERIC	国际长途闲时通话次数
	IDD_WK_CALL_LENGTH	NUMERIC	国际长途平时通话时长
	IDD_WK_CALL_CNT	NUMERIC	国际长途平时通话次数
	IDD_HL_CALL_LENGTH	NUMERIC	国际长途假日通话时长
	IDD_HL_CALL_CNT	NUMERIC	国际长途假日通话次数
	DDA_PK_CALL_LENGTH	NUMERIC	长途忙时通话时长



续表

类别	列 名 称	类 型	描 述
行为 信息	DDA_PK_CALL_CNT	NUMERIC	长途忙时通话次数
	DDA_OP_CALL_LENGTH	NUMERIC	长途闲时通话时长
	DDA_OP_CALL_CNT	NUMERIC	长途闲时通话次数
	DDA_WK_CALL_LENGTH	NUMERIC	长途平时通话时长
	DDA_WK_CALL_CNT	NUMERIC	长途平时通话次数
	DDA_HL_CALL_LENGTH	NUMERIC	长途假日通话时长
	DDA_HL_CALL_CNT	NUMERIC	长途假日通话次数
	DDA_CALL_LENGTH	NUMERIC	长途通话时长
	DDA_CALL_CNT	NUMERIC	长途通话次数
	DDA_CALL_CHG	NUMERIC	长途通话费用
	RM_CALL_LENGTH	NUMERIC	国内漫游通话时长
	RM_CALL_CNT	NUMERIC	国内漫游通话次数
	RM_CALL_CHG	NUMERIC	国内漫游通话费用
	IRM_CALL_LENGTH	NUMERIC	国际漫游通话时长
	IRM_CALL_CNT	NUMERIC	国际漫游通话次数
	IRM_CALL_CHG	NUMERIC	国际漫游通话费用
	RMA_CALL_LENGTH	NUMERIC	漫游通话时长
	RMA_CALL_CNT	NUMERIC	漫游通话次数
	RMA_CALL_CHG	NUMERIC	漫游通话费用
	MBX_CNT	NUMERIC	语音信箱/移动秘书次数
	VAS_CNT	NUMERIC	增值服务次数
	VAS_CHG	NUMERIC	增值服务费用
	HVAS_CNT	NUMERIC	高额增值服务次数
	HVAS_CHG	NUMERIC	高额增值服务费用
	SMS_CNT	NUMERIC	SMS 次数
	SMS_CHG	NUMERIC	SMS 费用
	SMS_CP_CNT	NUMERIC	发向竞争对手的 SMS 次数
	SP_CNT	NUMERIC	SP 次数
	SP_CHG	NUMERIC	SP 费用
	EBIZ_CNT	NUMERIC	电子商务次数
	EBIZ_CHG	NUMERIC	电子商务费用
	VH_CALL_CNT	NUMERIC	高额呼叫次数
	VL_CALL_CNT	NUMERIC	特长呼叫次数
	L_CALL_CNT	NUMERIC	长时呼叫次数
	M_CALL_CNT	NUMERIC	一般呼叫次数

续表

类别	列 名 称	类 型	描 述
行为 信息	S_CALL_CNT	NUMERIC	短时呼叫次数
	VS_CALL_CNT	NUMERIC	超短话单次数
	VL_FREE_CNT	NUMERIC	特长免费呼叫次数
	L_FREE_CNT	NUMERIC	长时免费呼叫次数
	M_FREE_CNT	NUMERIC	一般免费呼叫次数
	S_FREECNT	NUMERIC	短时免费呼叫次数
	VS_FREE_CNT	NUMERIC	超短免费话单次数
	LOC_VH_CALL_CNT	NUMERIC	区内高额呼叫次数
	LOC_VL_CALL_CNT	NUMERIC	区内特长呼叫次数
	LOC_L_CALL_CNT	NUMERIC	区内长时呼叫次数
	LOC_M_CALL_CNT	NUMERIC	区内一般呼叫次数
	LOC_S_CALL_CNT	NUMERIC	区内短时呼叫次数
	LOC_VS_CALL_CNT	NUMERIC	区内超短话单次数
	DDA_VH_CALL_CNT	NUMERIC	长途高额呼叫次数
	DDA_VL_CALL_CNT	NUMERIC	长途特长呼叫次数
	DDA_L_CALL_CNT	NUMERIC	长途长时呼叫次数
	DDA_M_CALL_CNT	NUMERIC	长途一般呼叫次数
	DDA_S_CALL_CNT	NUMERIC	长途短时呼叫次数
	DDA_VS_CALL_CNT	NUMERIC	长途超短话单次数
	RMA_VH_CALL_CNT	NUMERIC	漫游高额呼叫次数
	RMA_VL_CALL_CNT	NUMERIC	漫游特长呼叫次数
	RMA_L_CALL_CNT	NUMERIC	漫游长时呼叫次数
	RMA_M_CALL_CNT	NUMERIC	漫游一般呼叫次数
	RMA_S_CALL_CNT	NUMERIC	漫游短时呼叫次数
	RMA_VS_CALL_CNT	NUMERIC	漫游超短话单次数
	PK_VH_CALL_CNT	NUMERIC	忙时高额呼叫次数
	PK_VL_CALL_CNT	NUMERIC	忙时特长呼叫次数
	PK_L_CALL_CNT	NUMERIC	忙时长时呼叫次数
	PK_M_CALL_CNT	NUMERIC	忙时一般呼叫次数
	PK_S_CALL_CNT	NUMERIC	忙时短时呼叫次数
	PK_VS_CALL_CNT	NUMERIC	忙时超短话单次数
	OP_VH_CALL_CNT	NUMERIC	闲时高额呼叫次数
	OP_VL_CALL_CNT	NUMERIC	闲时特长呼叫次数
	OP_L_CALL_CNT	NUMERIC	闲时长时呼叫次数
	OP_M_CALL_CNT	NUMERIC	闲时一般呼叫次数



续表

类别	列 名 称	类 型	描 述
行为 信息	OP_S_CALL_CNT	NUMERIC	闲时短时呼叫次数
	OP_VS_CALL_CNT	NUMERIC	闲时超短话单次数
	HL_VH_CALL_CNT	NUMERIC	假日高额呼叫次数
	HL_VL_CALL_CNT	NUMERIC	假日特长呼叫次数
	HL_L_CALL_CNT	NUMERIC	假日长时呼叫次数
	HL_M_CALL_CNT	NUMERIC	假日一般呼叫次数
	HL_S_CALL_CNT	NUMERIC	假日短时呼叫次数
	HL_VS_CALL_CNT	NUMERIC	假日超短话单次数
	IP_CALL_LENGTH	NUMERIC	IP 长途通话时长
	IP_CALL_CNT	NUMERIC	IP 长途通话次数
	IP_CALL_CHG	NUMERIC	IP 长途通话费用
	IP_DD_CALL_LENGTH	NUMERIC	IP 国内长途通话时长
	IP_DD_CALL_CNT	NUMERIC	IP 国内长途通话次数
	IP_DD_CALL_CHG	NUMERIC	IP 国内长途通话费用
	IP_IDD_CALL_LENGTH	NUMERIC	IP 国际长途通话时长
	IP_IDD_CALL_CNT	NUMERIC	IP 国际长途通话次数
	IP_IDD_CALL_CHG	NUMERIC	IP 国际长途通话费用
	FW_LENGTH	NUMERIC	呼转到固话通话时长
	FW_CNT	NUMERIC	呼转到固话通话次数
	FW_CHG	NUMERIC	呼转到固话通话费用
	XFW_LENGTH	NUMERIC	呼转到小灵通通话时长
	XFW_CNT	NUMERIC	呼转到小灵通通话次数
	XFW_CHG	NUMERIC	呼转到小灵通通话费用
	CFW_LENGTH	NUMERIC	呼转到竞争对手号码通话时长
	CFW_CNT	NUMERIC	呼转到竞争对手号码通话次数
	CFW_CHG	NUMERIC	呼转到竞争对手号码通话费用
	FWA_LENGTH	NUMERIC	呼转通话时长
	FWA_CNT	NUMERIC	呼转通话次数
	FWA_CHG	NUMERIC	呼转通话费用
	CC_LENGTH	NUMERIC	呼叫竞争对手客服号通话时长
	CC_CNT	NUMERIC	呼叫竞争对手客服号通话次数
	AVG_SLP_LENGTH	NUMERIC	平均睡眠时间
	MAX_SLP_LENGTH	NUMERIC	最长睡眠时间
	AVG_DDA_SLP_LENGTH	NUMERIC	长途平均睡眠时间
	AVG_DDA_SLP_LENGTH	NUMERIC	长途最长睡眠时间

续表

类别	列 名 称	类 型	描 述
行为 信息	AVG_LOC_SLP_LENGTH	NUMERIC	区内通话平均睡眠时间
	AVG_LOC_SLP_LENGTH	NUMERIC	区内通话最长睡眠时间
	AVG_SMS_SLP_LENGTH	NUMERIC	SMS 平均睡眠时间
	AVG_SMS_SLP_LENGTH	NUMERIC	SMS 最长睡眠时间

10.3.3 分析过程

重入网识别主要包括基于手机 IMEI 串号和基于呼叫指纹两种方法。IMEI (International Mobile Equipment Identity, 国际移动装备标识码) 是由 15 位数字组成的电子串号, 与每台手机一一对应, 而且是全球唯一的。每部手机在组装完毕后都被赋予一个全球唯一的一组号码, 这个号码从生产到交付使用都将被制造生产的厂商记录。但是, 由于种种原因目前大多数 CDMA 用户 (WAP 用户除外) 无法获取 IMEI 串号。此外, 一些水货手机的 IMEI 串号无效等原因, 无法完全通过手机 IMEI 串号识别重入网。通常情况下, 将基于手机 IMEI 串号和基于呼叫指纹两种方法联合使用, 以确保重入网识别的准确率。所谓“呼叫指纹”是指用户在使用运营商的产品和服务过程中所产生的交往圈、呼叫特征、短信特征、位置特征、客服特征和终端特征等信息。由于这些信息对于一个用户而言是相对稳定的, 且不同用户之间具有较大差异, 因此可用于识别重入网。基于呼叫指纹的重入网识别是根据历史用户已经发生的通话行为, 经过分析, 从通话呼叫行为中发现用户通话习惯、行为和交际圈等特征, 利用这些显著特征标识用户, 建立用户的呼叫行为档案, 如同用户的“指纹”一样, 每个用户的呼叫行为都不尽相同。通过广泛的用户呼叫行为分析, 建立呼叫指纹库。在识别重入网用户时, 首先在新发展用户群中过滤出疑似重入网用户, 然后对疑似用户进行呼叫行为分析, 同样可以获得用户呼叫行为特征, 将新的呼叫行为特征纳入已经建立的呼叫指纹库, 通过对比新旧呼叫指纹的相似度, 最终判断疑似用户是否为重入网用户。

基于呼叫指纹的重入网识别过程描述如下:

1. 确定待识别用户和新入网用户清单

呼叫指纹识别需要建立新入网用户群和待识别用户群两个数据集。

2. 选择特征变量和数据清洗

首先需要通过数据挖掘方法筛选合适的特征变量, 表 10.10 列出了部分关键指标。

表 10.10 重入网识别的部分关键指标

序号	指 标 名 称	序号	指 标 名 称
1	前 10 个最频繁通话号码重合率	7	通话小区数的变异率
2	前 10 个最长的总通话时长号码重合率	8	本网交际圈人数的重合率
3	前 10 个最长的单次通话时长号码重合率	9	他网交际圈人数的变异率
4	前 10 个总通话次数最多号码重合率	10	前 10 个最频繁通话时段的重合率
5	前 10 个点对点发送短信最频繁号码的重合率	⋮	⋮
6	点对点短信次数的变异率		



### 3. 建立呼叫指纹库

建立呼叫指纹库的关键是筛选出可以辨别不同用户身份的特征号码库,并逐一计算其权重,即建立特征号码权重库。首先,统计用户拨打的所有特征电话号码的频次,从高到低排序,剔除拨打频次最高的一部分公共号码以及拨打频次最低的一部分稀疏号码,这些号码对于区分用户的呼叫指纹没有实际意义;然后,对剩余的特征号码赋予不同的权重,建立特征号码权重库。

特征号码权重的计算采用 TF-IDF 算法,它是由 Salton 和 McGill 在 1983 年针对向量空间信息检索范例(vector space information retrieval paradigm)提出的文档特征表示方法。其中,TF(Term Frequency)为主题词频度,即出题词  $t_i$  在文档  $d$  中出现的次数,记为  $tf(t_i, d)$ ; DF(Document Frequency)为出题词的文档频度,即文档集中出现出题词  $t_i$  的文档数量,记为  $df(t_i)$ ; IDF(Inverse Document Frequency)为出题词的反文档频度,即

$$idf(t_i) = \log\left(\frac{n}{df(t_i)}\right)$$

其中  $n$  表示文档集的文档总数。TF-IDF 算法是将文档以特征向量表示为  $d(w_1, w_2, \dots, w_n)$ ,对应项  $t_i$  的权重  $w_i = tf(t_i, d) \times idf(t_i)$ 。

重入网识别引入 TF-IDF 算法的优势在于随着用户拨打特征号码  $t_i$  次数的增加,即随着用户拨打相同的特征号码次数的增加,则  $tf(t_i, d)$  的值增加,该特征号码的权重将增加,这与我们通常的理解一致;如果该特征号码被许多用户所拨打,则  $idf(t_i)$  的值反而减小,特征号码的权重将减小,表明该特征号码对辨别用户身份的作用将减小,这是因为如果该特征号码也被其他用户频繁地拨打,如公共号码,则其分辨个体特征的能力相对减弱,所以其权重应当减小,以便使那些更能分辨用户是否具有相似呼叫指纹的特征号码的权重相应增大。

采用 TF-IDF 算法在一定程度上减少了“噪声”号码对判别准确度的影响,突出重要的特征号码,同时又考虑了整个呼叫指纹库呼叫特征之间的关系。因此如果样本量足够,最终重入网识别具有较高的准确率。

### 4. 计算呼叫指纹相似度

呼叫指纹相似度是指新入网用户与待识别用户之间的相似程度,即每个特征变量的重合率或变异率的加权值,其计算公式为:

$$S = a_1x_1 + a_2x_2 + \dots + a_nx_n \quad (10.6)$$

其中,  $x_i$  代表新入网用户与待识别用户在第  $i$  个特征变量的重合率或变异率,  $a_i$  代表每个特征变量的权重,根据其在重入网识别中的重要程度可以动态调整。

### 5. 设定呼叫指纹相似度阈值

大于该阈值的待识别用户对可界定为疑似重入网用户。

### 6. 验证

通过电话外呼或客户资料比照可以对疑似重入网用户进行验证以最终锁定,检验模型的准确性及覆盖率是否达到预期要求,如果达不到要求则需要调整模型。

锁定重入网用户后,需要进一步将重入网用户与订购套餐/产品、渠道等进行关联分析,发现引起重入网的症结所在,推荐合适的套餐,降低客户离网率和客户欠费风险以及经营风险。

基于手机 IMEI 串号的重入网识别需要进行数据清洗以排除噪声,即排除错误的、非法



烧录的、空缺的 IMEI 串号等,然后对 IMEI 串号进行逐一扫描和匹配,定位重入网用户。

#### 10.3.4 结果

利用基于手机 IMEI 串号和基于呼叫指纹两种重入网用户识别方法,对某市 2008 年 9 月流失的 CDMA 用户 45537 户和 2008 年 9~10 月两个月新发展的 CDMA 用户 135638 户进行重入网甄别,通过匹配找到拨打过相同特征号码的用户对共计 193281,其中大部分流失用户在新入网用户中都能找到多于 1 个的匹配用户,逐一计算相似度,设定一定的相似度阈值,发现疑似重入网用户 12596,对这些疑似重入网用户进行客户资料比对和电话回访进行确认,最终锁定重入网用户 10791,占 2008 年 9 月流失的 CDMA 用户的 23.7%。

重入网识别的实际意义和作用体现在:

##### 1. 调整新入网政策

(1) 针对部分客户自身的流动性和不稳定性,对具有流动性的客户可以采取针对性的捆绑措施,挽留客户。

(2) 对于新发展用户中不少用户入网定位不准,进行深度客户细分,并有针对性地提前开展主动的市场梳理,减少重入网现象。

(3) 对重入网用户开展重入网原因和政策了解程度的调查,调整产品和套餐漏洞,减少成本和收入损失。

##### 2. 调整代理商佣金政策

代理商佣金侧重奖励新发展的非重入网用户,适当降低新发展的重入网用户的佣金标准。

此外,通过用户、业务、品牌、渠道、消费层次和生命周期等多方面对重入网现象进行分析,找出不足并采取措施。

### 10.4 WAP 日志挖掘

中国通信业的快速发展令世界瞩目,截至 2009 年 7 月,中国移动电话用户达到 7.03 亿户。全球移动电话用户数约 44 亿,普及率达 65%;全球互联网用户数超过 15 亿,普及率达 22%。目前,中国的移动手机用户数和互联网用户数均居世界第一。随着 3G(the 3rd Generation)牌照陆续发放,3G 的到来加速了移动通信和互联网的融合,并呈现三个趋势,即互联网接入的移动化、移动业务的互联网化、互联网业务的移动化。

由于传统语音业务的价格持续下滑,促使运营商开始转变收入重点,将数据业务逐步调整为未来利润的主要来源,数据业务被普遍认为是电信运营商的下一个金矿。而 WAP(Wireless Application Protocol)业务是当前网络环境下最重要的数据业务之一,几乎所有的手机终端均内置了 WAP 浏览器,使得大量成熟的数据业务以 WAP 作为重要的推广渠道,WAP 业务在运营商的业务架构中地位越来越重要,其用户数量也在飞速发展。但是随着用户数量的快速增长,WAP 业务质量却没有跟上用户发展的脚步。WAP 业务同质化严重,SP(Service Provider,服务提供商)的注意力集中在如何从用户身上获得更多的资费,甚至利用 WAP 业务中的一些技术漏洞强行绑定用户,引起大量的投诉。但随着电信运营商



对 WAP 业务管理的逐步规范,对 WAP 用户的使用行为进行深入挖掘成为必然,并具有重要的现实意义。

### 10.4.1 定义

WAP 日志在一定程度上反映了 WAP 用户的使用行为习惯和特征,主要包括系统日志和用户访问日志。系统日志记录了 WAP 服务器在运行过程中系统的各种状态,为改进服务器性能、故障排除等提供了重要的参考依据,可以帮助系统维护人员快速定位故障并解决;用户访问日志记录了用户浏览 WAP 页面时的各种信息,包括用户访问时间、访问页面地址、访问机型参数、用户 IP 地址和用户标识等。

不同的系统会产生不同格式的 WAP 日志,根据系统性能需求系统管理员可以配置服务器产生日志的复杂度。在服务器空间有限且性能不高的情况下,可以缩减日志参数,仅记录与用户访问信息相关的内容。在服务器硬件条件允许的情况下,建议尽可能多地记录用户访问参数,因为在日志提取阶段很难判断日志参数在未来挖掘中的价值,尽可能多地保留以避免具有潜在价值的数据丢失。

这里的 WAP 日志是基于微软公司的 Internet Information Services 5.0 生成的,按照日期对日志进行命名,每天的用户访问日志存储在一个文本文件中,如 20091001.txt。日志文件中各参数之间用空格分开,一行为一个用户的访问行为。

WAP 日志的具体参数名称和含义如表 10.11 所示。

表 10.11 WAP 日志参数

参数名称	含 义	功 能	实 例
Date	日期	用户访问 WAP 的日期	如 2009-07-25
Time	时间	用户访问 WAP 的时间	如 00:00:01
c-IP	用户访问 IP	访问用户的 IP 地址	如 211.137.167.133
CS-username	访问用户名	访问 WAP 的用户名	
s-IP	服务器端 IP	用户访问 WAP 页面对应的服务器端地址	如 211.157.8.68
s-port	服务器端口	用户访问 WAP 页面对应的服务器端口	如 8080
CS-method	请求方式	客户端操作请求的种类	如 GET,POST
CS-URI-stem	请求内容名称	用户访问的 WAP 页面地址	如 /desk/cxzd/intro.asp
CS-URI-query	请求内容参数	用户访问 WAP 页面地址所带的参数	如 MISC_ID=999&MISC_SessionID=999
sc-status	状态代码	用户访问 WAP 页面的状态代码	如 200,302
CS-User-Agent	用户代理	用户访问 WAP 所使用的手机型号	如 Nokia3108

### 10.4.2 数据准备

数据准备阶段的工作主要是选择合适的数据源,整理分析所需的 WAP 日志数据,对原始数据进行检查和预处理,生成新的衍生变量,并整理成适合分析使用的数据宽表。

数据准备过程如下:

#### 1. 选择数据分析范围

根据需求选取中国移动梦网某一 WAP 产品 2008 年 3~6 月连续四个月的用户访问日志作为分析对象。

#### 2. 收集原始数据

WAP 产品日志是原始文件,和互联网站日志类似,其中记录了用户在浏览 WAP 页面过程中的大量信息。不同的服务器系统所产生的日志略有不同,大多都包括用户 IP 地址、访问终端类型、访问时间、所访问页面地址等,而移动梦网 WAP 产品同时还可以获得用户手机号码,这是区别于互联网日志的一个重要特点,即电信业务最大的特质——用户个性化标识。针对用户的个性化行为分析将紧密围绕着这一标识进行。

#### 3. 数据清洗

日志一般存储在文本文件中,虽然大多是按照一定规则记录的,但在后继的分析中通过文本文件进行信息的查找较为不便,故需要把日志内容导入到数据库或更好的存储介质中以便操作。此过程尽量避免将日志中包含的信息删掉,让日志信息尽量完整地在新存储介质中得到展现。

#### 4. 检查数据质量

可以通过对所提取数据的时间分布进行直观观察,对异常时间点进行针对性分析;也可以观察所提取参数的数值分布,对其可靠性进行评估。由于用户使用 WAP 的行为具有较强的周期性,可以比对不同周期的相同时间点,检验异常数据。

#### 5. 计算衍生变量

对 WAP 用户的使用行为数据进行加工处理,生成新的衍生变量。

#### 6. 合并生成宽表

按照用户 ID 合并地域、终端、产品内容和用户四类指标,生成一张数据宽表,其中每行代表一个用户,每列代表一个变量,如表 10.12 所示。

表 10.12 数据宽表

	名 称	含 义	功 能	说 明
地域类	地域名称	省份名称	标识分析结果所对应的省份	日志中用户参数的前四位标识用户所在区域,可通过对照区域编号表确定访问用户所在区域
	时间	数据产生的时间,以天为统计单位	反映产品运营过程中的时间变化趋势	日志中的时间参数
	累计浏览用户数	从产品投入运营至今访问过 WAP 产品的用户总数	反映产品投入运营后各地用户的规模	对日志中的用户标识进行排重,计算当天访问用户数,再与之前累计用户数相加



续表

地域类	名 称	含 义	功 能	说 明
	浏览用户数	统计期内浏览过WAP产品的用户数	当日访问WAP产品的用户数	对日志中的用户标识进行排重
	新增浏览用户数	统计期内浏览用户数较前一日增加的数量	衡量浏览WAP产品的用户数量变化情况,常用于异常检验	当日与前一日浏览用户数之差
	订阅用户数	有过订阅频道行为的用户数	反映用户订阅WAP业务的活跃程度(由于该WAP产品采用类似于RSS的订阅模式,在用户浏览内容前先要进行频道订阅)	用户订阅成功后,访问频道日志文件将记录用户所访问的频道参数,根据参数即可判断用户是否为订阅用户
	订购套餐用户数/收费用户数	订购收费套餐的用户数量	描述用户对价格敏感的程度,以及对收费频道的认可度(该WAP分为收费频道和免费频道两种,对于优质内容用户需要付费才能浏览)	计算日志文件中访问“订购成功”页面的用户数进而得到当天订购套餐用户数
	新增收费用户数	当日新增的收费用户数	描述收费用户数的变化情况,可了解WAP产品收入的变化趋势	计算当日收费用户数和前一日收费用户数之差
	主动浏览用户数	浏览详细内容的用户数	描述用户对每日更新内容的兴趣程度(该WAP产品采用先浏览内容摘要,用户对详细内容感兴趣再点击浏览完整的文章内容的模式)	提取日志中访问详细内容页面的用户行为记录
	主动浏览用户占比	主动浏览用户在浏览用户的占比	反映对WAP产品感兴趣的用户占整体用户群的比例	主动浏览用户数除以浏览用户数
	浏览用户占比	浏览用户在累计访问用户的占比	用户对WAP产品整体的认知度	浏览用户数除以累计访问用户数
	人均主动浏览次数	统计期内平均每个用户的主动浏览次数	用户对产品内容的兴趣程度	计算所有用户访问详细页面时产生的页面参数的总数,然后除以访问用户数
	人均订阅频道数	累计访问用户中平均每个用户订阅频道数量	用户对于WAP产品的频道内容的兴趣度	订阅用户数除以累计访问用户数
	添加频道用户数	统计期内添加频道的用户数	反映每日用户添加频道的活跃程度,可以得出用户心理的周期性规律	无
	删除频道用户数	统计期内删除频道的用户数	反映每日用户删除频道的情况	无

续表

	名 称	含 义	功 能	说 明
终端类	终端名称	数据对应的终端名称	标识分析结果对应的终端	用户访问 WAP 服务器时,日志会记录用户的 user-agent 即手机标识,简称 UA。利用 UA 与终端名称的对应表得到准确的终端型号
	时间	数据产生的时间,以天为统计单位	反映产品运营过程的变化趋势	日志中的时间参数
	累计浏览用户数	从产品投入运营至今,曾经通过终端访问 WAP 产品的用户总数	衡量产品投入运营后各终端用户的规模	对于不同型号终端的用户行为日志进行排重,得到当天访问用户数,再与之前累计用户数相加
	浏览用户数	统计期内通过终端浏览过 WAP 产品的用户数	当日访问 WAP 产品的用户数	对用户行为数据基于用户标识进行排重,得到当天浏览用户数
	新增浏览用户数	统计期内通过终端浏览的用户数较前一日增加的数量	衡量各终端用户浏览产品的变化情况,常用于趋势分析及异常检验	计算某终端当日与前一日浏览用户数之差
	订 阅 用 户 数	某终端有过订阅频道行为的用户数	各终端用户订阅频道的活跃程度	用户订阅成功访问频道时,日志将记录用户所访问的频道参数,根据参数即可判断用户是否为订阅用户
	订购套餐用户数/收费用户数	某终端订购收费套餐的用户数	各终端对价格敏感的程度	以 UA 为标识计算日志中访问了“订购成功”页面的用户数,得到当天某终端订购套餐用户数
	新增收费用户数	统计期内某终端新增的收费用户数	某终端收费用户数的变化情况	某终端的当日收费用户数减去前一日收费用户数
	主动浏览用户数	某终端用户浏览详细内容的数量	各终端用户对每日更新内容的兴趣程度	提取日志中某终端访问详细内容页面的行为记录
	主动浏览用户占比	某终端主动浏览用户在浏览用户的占比	反映某终端对 WAP 产品感兴趣的用户占整体用户群的比例	主动浏览用户数除以浏览用户数
	浏览用户占比	某终端浏览用户数在累计访问用户的占比	某终端用户对 WAP 产品整体的认知度	浏览用户数除以累计访问用户数
	人均主动浏览次数	统计期内某终端平均每个用户的主动浏览次数	某终端用户对产品内容的兴趣程度	计算某终端的所有用户访问详细页面产生的页面参数的总数,然后除以访问用户数
	人均订阅频道数	某终端累计访问用户中平均每个用户订阅频道数	各终端用户对于 WAP 产品的频道内容的兴趣度	订阅用户数除以累计访问用户数
	添加频道用户数	统计期内某终端添加频道的用户数	每日某终端用户添加频道的活跃程度	通过日志文件对添加频道成功页面的访问记录,以终端型号、用户手机号为标识,计算添加频道用户的总数
	删除频道用户数	统计期内某终端删除频道的用户数	某终端用户删除频道的情况	无



续表

	名 称	含 义	功 能	说 明
产 品 内 容 类	时间	数据产生的时间,以天为统计单位	反应频道数据的变化趋势	日志中的时间参数
	频道名称	数据对应的频道名称	标识分析结果对应的频道	用户访问 WAP 服务器时,日志会记录用户所访问的频道参数,利用参数与频道名称的对应表可获得用户访问的频道名称
	频道类型	频道的分类	频道类型分为初始频道和可选频道(该 WAP 产品对免费用户默认设置三个初始频道,便于用户体验)	先利用用户访问记录得出所访问频道的参数,再利用频道参数对应表可获得访问频道类型
	计费方式	收费/免费方式计费	频道的收费方式	先利用用户访问记录得出所访问的频道参数,再利用频道参数对应表可获得频道计费方式
	订 阅 用 户 数	订阅某频道的用户总数	用户订阅频道的活跃程度	分析每日用户访问“订阅成功”页面的日志,通过频道参数对应表可获得用户新订阅的频道名称,再将新的订阅信息插入到用户频道订阅表中存储
	新增订阅 用户数	统计期内新增的订阅用户数	反映各频道订阅用户数的变化情况,便于对频道发展情况做出预测	统计周期内对用户访问“订阅成功”页面的所产生的日志文件进行分析,通过频道参数对应表获得用户新订阅的频道名称
	退 订 用 户 数	统计期内,用户取消订阅某频道的用户数	反映用户对哪些频道内容不满意	对用户访问“删除频道成功”页面产生的日志进行分析,通过频道参数对应表获得用户退订频道名称,并插入到用户订阅/退订频道历史数据库
	主动浏览 用户数	统计期内浏览某频道详细内容的用户总数	用户对频道内容的兴趣度	利用用户访问详细内容页面时日志记录的频道参数,通过频道参数对应表获得所要统计的频道数据,再结合用户标识得出主动浏览用户数
	浏 览 用 户 数	统计期内浏览某频道的用户数	用户对频道的兴趣程度	利用用户访问频道页面时日志记录的频道参数,通过频道参数对应表获得所要统计的频道名称,再结合用户标识得到浏览用户总数
	主动浏览 用户占比	统计期内某频道浏览详细页面的用户数在所有访问该频道用户数的占比	频道内容对用户的吸引程度	主动浏览用户数除以浏览用户数
	人均主动 浏览次数	统计期内平均每个用户浏览该频道详细内容的次数	反映频道的粘性	利用日志记录的访问频道参数,算出访问频道页面的次数,除以主动浏览用户数

续表

	名 称	含 义	功 能	说 明
用户类	用户 ID	唯一标识用户的字符串	唯一标识用户	日志中记录访问用户的用户 ID 标识
	城市名称	用户所在城市	反映地域差异对于用户使用行为的影响	根据日志文件中记录的用户访问 IP 地址,与各地市 IP 地址表进行比照获得用户使用业务所在地
	终端型号	用户使用终端的型号	反映终端差异对于用户使用行为的影响	用户访问 WAP 服务器时,日志会记录用户的 user-agent(即手机标识,简称 UA),利用 UA 与终端名称的对应表获得准确的终端型号
	频道订购情况	用户是否订阅该频道(包括 22 列,每列为一个频道)	反映当前用户群订阅频道的分布情况	通过用户订阅频道历史数据表获得

10.4.3 分析过程

具体的分析过程如下:

1. 数据整合

由于数据仓库中地区、终端、频道等相对独立,所以需要先将这些数据进行整合,最终得到完整的用户订阅频道信息表。先利用用户订阅信息表中的 user\_id、city\_id、region\_id、mobile\_type 等字段进行关联,把之前可读性较差的数字表示形式替换为具有直观意义的字符串形式(在进行挖掘过程中就不需要再到历史数据中查找相关参数),然后将表中的 null 值替换成 F,这样订阅频道的相关信息就以布尔值 F 和 T 表示。最后对处理结果进行检查,提高数据质量。

2. 聚类

因为 TwoStep 聚类算法可以自行根据数据的分布进行类数选择,所以先利用 TwoStep,并将类别数作为后继 k means 聚类的输入参数,以获得数量较平均且类之间距离较大的最佳聚类结果。

3. 结果展示

网络图可以直观展现聚类结果,例如订阅娱乐频道的用户数中有很多同时订阅了焦点评论,在网络图中两个频道点之间会形成一条很粗的线,以表示两者之间呈较强的相关性。各点之间的线段即表示两个频道的关系,线段越粗相关性越大,越细相关性越小。网络图提供动态的展现方式,分析人员可以通过改变条件,以便将关联度高(线条越粗)的各组频道关系从繁杂的关系中提取出来。

4. 解释和评价

首先对聚类结果进行直观观察,通过分布了解聚类的用户群,然后将聚类结果作为输出变量,地区、终端类型、各频道的订阅情况作为输入变量,利用决策树进行聚类结果的解析,从而以逻辑表达式解释聚类结果。



### 10.4.4 结果

根据上述分析过程,分析结果如表 10.13 所示。

表 10.13 WAP 日志聚类结果

序号	类别名称	订购行为特点	营 销 方 案
1	证券型	此类用户对证券、财经极其关注	可以定向推送证券相关的增值信息(例如手机证券报),也可将与证券相关的内容进行打包,作为提升 WAP 业务订购的一种手段。关注证券相关内容的用户往往是非常活跃的用户,各种信息的获取需求很大,是点击次数产生的主要用户群。基于此用户群特质,可通过 WAP 内嵌广告的方式转化为收入,达到最佳的盈利模式
2	娱乐型	此类用户对星座、动漫非常关注	通过此类用户订购情况看,可以判断此用户群以年轻学生群体为主,接收新鲜事物很快,对价格敏感,有较强的发表观点的意愿,渴望自我实现。可以增加评论等社区功能,为用户主动推荐“娱乐”、“时尚”等年轻人可能感兴趣的频道,充分迎合年轻群体的需求
3	体育型、男性化	此类用户对体育、军事很感兴趣	通过此类用户订阅情况看,可以判断此用户群具有男性化的特质。对于体育方面的内容可以进行领域细分(如体育可分为篮球、足球等),提高用户获取信息的准确性。也可引入 WAP 赛事直播的方法,让对比赛感兴趣但无法收看电视转播的人群,通过文字的方式实时了解赛事情况,从而提高产品的粘性。对于军事方面的内容,可以增加时事政治方面的内容推荐,让用户有一个更加全面的军事视角。根据男性特质该用户群还可以提供“创业”、“女性”等相关内容,以开辟吸引此类用户新的内容领域
4	成熟型	此类用户对军事、焦点评论、证券很感兴趣	此用户群所感兴趣的内容有较强的深度,可归于成熟型用户。对这类用户最重要的就是所选内容的价值,若能够满足其对深度内容的需求,单个用户的 ARPU 值会较高

通过网络图可以了解 WAP 产品整体用户类型情况,在营销资源有限而导致不能针对分类用户群进行精确营销的前提下,可先对整体用户群进行营销,大大提高运营分析转化为实际运营的可行性。

每个频道在网络图中均以一点表示,而点之间的线段表示频道间关系的关联程度。图 10.12 是将所有的关系进行呈现,关系看起来很复杂,可以通过调节阈值加以过滤,进而发现强关联。




图 10.12 初始的网络图

设定适当的阈值,形成图 10.13 所示的关系图。由图 10.13 可知,该 WAP 业务订阅最多的四个频道分别是娱乐、轻松一刻、生活和焦点评论,并且各频道之间都存在较强的关联,形成了 WAP 业务客户群频道订阅的基础组合。




图 10.13 过滤后的网络图



# 第 三 篇

## 语义网和本体

第11章 知识

第12章 语义网和本体





## 第 11 章 知 识

知识是人们日常生活及社会活动中常用术语之一。例如人们常说“知识就是力量”、“应该多学点知识”等。什么是知识？知识有哪些特点？它与平常所说的信息有什么区别？如何表示知识？知识表示与人工智能、知识工程的关系如何？针对上述问题，本章将从知识的定义、分类、度量和表示等几方面进行阐述。

### 11.1 概述

#### 1. 数据

人类赖以生存的空间是一个物质的世界，同时又是一个信息的世界。在这个不断变化的世界中，无论是政治、经济、军事方面，还是科技、文化、教育等方面，时时刻刻都在产生大量的信息。谁能及时地掌握有用信息，并能把有关信息关联起来加以充分利用，谁就能在激烈的竞争中立于不败之地。随着社会的发展和进步，信息在人类生活中越来越扮演着极其重要的角色。但是，信息是需要用一定的形式表示才能被记载和传递，尤其是使用计算机进行信息的存储和处理时，更需要用一组符号及其组合进行表示。像这样用一组符号及其组合表示的信息称为数据。

由此可见，这里所说的数据已不仅仅是通常意义下的“数”，而是概念上的延伸，泛指对客观事物的数量、属性、位置及其相互关系的抽象表示。它既可以是一个数，如整数、小数、正数和负数，也可以是由一组符号组成的字符串，如姓名、性别、地址或消息等。

数据和信息是两个密切相关的概念。数据是信息的载体和表示，信息是数据在特定场合下的具体含义，换言之信息是数据的语义，只有把两者密切地结合起来，才能实现对现实世界中某一具体事物的描述。另外，数据和信息又是两个不同的概念。对于同一个数据，在某一场合下可能表示一个信息，但在另一场合下却可能表示另一个信息。例如数字 6 是一个数据，既可以表示“6 本书”、“6 支铅笔”，也可以表示“6 个人”或“6 部手机”等。同样，对同一个信息，在不同场合下也可用不同的数据表示，如同对于同样的一句话，不同的人会用不同的言语来表达一样。

#### 2. 信息

20 世纪 40 年代末，美国数学家香农提出信息熵的数学公式，从量的方面描述了信息传输和提取问题，创立了信息论。首先，信息论在通信工程领域得到广泛应用，为信息科学的研究奠定了初步基础。

在消息传递系统中所传输的是消息，但消息传递过程中，最普遍却容易被忽视的一点是接收者在收到消息之前是不知道消息具体内容的。对于接收者而言，消息的传递过程是一个从不知到知的过程，或者说是一个从不确定到确定的过程。

从通信过程来看，接收者的所谓不知就是不知道发送端将发送描述何种运动状态的消息。例如看天气预报前，并不清楚天气将如何；看天气预报后，这种不确定性大大减小。不



确定性消除了,接收者就获得了信息。因此香农认为,信息是被消除的不确定性。

关于信息的定义,后来的学者又有种种讨论。由于信息概念的复杂性,在定义信息时必须十分注意定义的条件,应当根据不同的条件区分不同的层次给出信息的定义。最高的层次是普遍的层次,也是无条件约束的层次,称之为本体论层次。在这一层次上定义的信息是最广义的信息,其适用最广。然后,如果引入一个条件加以约束,则最高层次的定义就变为次高层次的定义,次高层次信息定义的适用范围比最高层次定义的适用范围要窄,所引入的约束条件越多,定义的层次越低,所定义信息的适用范围就越窄。这样,根据引入条件的不同,可以给出不同层次和不同适用范围的信息定义,这些不同的信息定义构成了信息定义的体系,即:

- 本体论层次的信息是事物运动的状态和状态改变的方式。
- 认识论层次的信息是认识主体所感知或所表述的事物运动的状态和方式。
- 语法信息是认识主体所感知或所表述的事物运动状态和方式的形式化关系。
- 语义信息是认识主体所感知或所表述的事物运动状态和方式的逻辑含义。
- 语用信息是认识主体所感知或所表述的事物运动状态和方式相对于某种目的的效用。
- 先验信息是指观察者在观察某事物之前通过某种途径所感知的该事物运动状态和方式。
- 实得信息是指在观察过程中,观察者通过观察所新感知到的该事物运动状态和方式。
- 实在信息是指该事物实际的运动状态和方式,这也是在理想观察条件下观察者所获得的关于该事物的全部信息。

上述语法信息、语义信息、语用信息、先验信息、实得信息和实在信息都是认识论层次上的各种信息概念。进一步,如果不仅对观察者施加各种限制条件,而且对所观察的事物也规定一些限制性约束,则会得到层次更低、适用范围更小的信息定义。例如,如果限定所观察事物的运动方式是随机型的,则可以分别得出概率性的实在语法信息、概率性的先验语法信息、概率性的实得语法信息等;如果限定所观察事物的运动方式是半随机型的,则可以分别得到偶发性的实在语法信息、偶发性的先验语法信息、偶发性的实得语法信息等;如果限定所观察事物的运动方式是确定性的而运动状态是模糊的,则可以分别得到模糊实在语法信息、模糊先验语法信息、模糊实得语法信息等。类似的情形也适用于语义和语用信息。总之,对观察者、观察对象(即事物)以及观察过程的性质都可以规定各种不同的条件,因此可以获得层次高低不同、适用范围各异的各种信息定义。

### 3. 知识

从古希腊开始,人类从未停止对于知识的研究与探索。哲学家研究有关知识的一般特性与规律,而自然科学家孜孜不倦地获取具体的知识。20世纪中叶后,这种研究格局发生了变化。由于知识在人类文明中发挥的作用越来越大,不仅是哲学家、逻辑学家、教育学家和心理学家,而且计算机科学家都在认真地研究知识的一般特性与规律。这是因为人类已经进入了信息化社会,而且正在向知识化社会迈进。

古希腊哲学家苏格拉底认为知识的唯一功能 is 自我认识,即人的智力、道德和精神的生活成长;毕达格拉斯认为知识的目的是通过使用知识的人知道他想说什么和怎么说,从而



使其行为更有效,知识就是指逻辑、语法和修辞;中国儒家则认为知识是知道说什么、怎么说以及出人头地和俗世成功的途径。对于道家而言,知识是自我认识和通向领悟智慧的途径。

知识工程的创始人 Feigenbaum 教授曾经说过“知识和信息不一样,知识是信息经过加工整理、解释、挑选和改造形成的”。可以说,这是从广义信息论的角度对知识进行定义。

如上所述,信息在人类生活中占据着相当重要的地位。但是,只有把有关的信息关联在一起时才具有实际意义。一般地,把有关信息关联在一起形成的信息结构称为知识。一些具有代表性的知识定义如表 11.1 所示。

表 11.1 代表性的知识定义

序号	知识定义
1	知识是通过实践、研究、联系或调查获得的关于事物的事实和状态的认识
2	知识是对科学、艺术或技术的理解,是人类获得的关于真理和原理的认识总和
3	知识是人们在长期的生活及社会实践中、科学研究及实验中积累起来的对客观世界的认识与经验,人们把实践中获得的信息关联在一起,就获得了知识
4	知识是把有关信息关联在一起所形成的信息结构
5	知识是人类在实践的基础上产生又经过实践检验的对客观实际可靠的反映
6	知识是人脑创新的成果,是人类智慧的结晶。智慧是人类文明的源泉,是推动历史发展的永恒动力,是生产力诸要素中的核心

知识是人们在长期的生活及社会实践、科学研究及实验中积累起来的对客观世界的认识与经验,人们把实践中获得的信息关联在一起,就获得了知识。信息之间有多种关联形式,其中用得最多的一种是“如果,则”表示的关联形式,反映了信息间的某种因果关系。例如我国的北方人经过多年的观察发现,每当冬天来临时,就会看到一群群的大雁向南方飞去,于是把“大雁南飞”与“冬天将要来临”这两个信息关联在一起,就得到了“如果大雁向南飞,则冬天将要来临”这样一条知识。

知识反映了客观世界中事物之间的关系,不同事物或者相同事物间的不同关系形成了不同的知识。例如“雪是白色的”是一条知识,反映了“雪”与“颜色”之间的一种关系;“如果头痛且流涕,则有可能患感冒”是一条知识,反映了“头痛且流涕”与“可能患感冒”之间的一种因果关系。

#### 4. 信息和知识的关系

马克思曾说过“任何科学只有在具有数学基础以后,才能算得上是真正的科学(大意)。”我们首先从数学的角度区分信息和知识这两个概念。

香农曾经对信息的数学本质进行研究,提出并回答了从数学的观点看,信息是什么的问题。他认为信息是一个数学量,用来消除不确定性。这种不确定性可以用具有概率意义的熵度量。由此,概率论成为研究信息论的基本数学工具。

如前所述,知识是结构化的信息,或者说知识是用于消除信息的无结构性。在这一观点中,知识的数学基础应该和信息的不同,其核心不是概率论,应该是描述结构的某种数学模型。寻求并分析这种结构,有望建立知识的数学描述。目前,国际上关于知识本体的研究备受关注,证实了知识结构性是一个根本问题的观点是有道理的,本体就是知识结构性的基本描述,这一点已经成为国内外有关专家的共识。



## 5. 表示与知识表示

表示是使用人造的体系(典型的例子是数学)对自然界事物的运动规律进行概括和抽象的模型,而这一模型可以预言自然界这种运动的所有情况。一旦这样的表示被找到,人们就认为这是对这类运动规律更深刻的认识。相比于自然的表示方法,它具有抽象性、深刻性和简洁性。对这种抽象意义上的表示,自然界中的物体是否可被感知,对表示没有什么直接的关系。换言之,表示与自然现象之间的形态上可以没有任何相同之处,它是自然现象在人为体系(公理)下的一种解释。

传统意义上,知识表示(knowledge representation)是概括智能行为的模型,属于人工智能的范畴,其特点是:

- 智能行为所特有的灵活性问题(常识问题)不能概括为一类简洁的理论,它是大量小理论的集合。
- 人工智能受到计算装置的约束。这就导致所采用的表示必须同时满足“刻画智能现象”与“计算装置可接受”这两个有时是矛盾的条件。正是对这两个条件的不同侧重导致了对表示的不同认识,并由此产生不同的方法论。

可以说,知识表示是众多理论与技术的交叉学科,主要源于:

- 逻辑提供推理规则和形式化结构
- 本体定义应用领域的各种存在
- 计算支持知识表示从哲学到应用层面的实现

如果没有逻辑,知识表示不可能明确,无法判别陈述是否矛盾或冗余;如果没有本体,词汇、符号等就不能被很好地定义和使用,概念就不会具有很好的一致性;如果缺乏可计算的模型,逻辑和本体就不能由计算机程序实现,就不能获得具体应用。因此知识表示是逻辑和本体为了实现某些领域特定应用的任务而建立的计算模型。

## 6. 人工智能与知识工程

人工智能主要研究采用人工的方法和技术模仿、延伸和扩展人的智能,实现机器智能。有人把人工智能划分为两大类:一类是符号智能,另一类是计算智能。符号智能是以知识为基础,通过推理进行问题求解,即所谓传统的人工智能;计算智能是以数据为基础,通过训练建立联系进行问题求解,如人工神经网络、遗传算法、模糊系统和人工生命等都可以包括在计算智能的范畴。

传统的人工智能主要运用知识进行问题求解。从实用观点看,人工智能是一门知识工程学,即以知识为对象,研究知识表示方法、知识运用和知识获取。

自1956年提出人工智能以来,已经取得了很大的进展和成功。1976年Newell和Simon提出了物理符号系统假设,认为物理符号系统是表现智能行为的必要和充分条件。这样,可以把任何信息加工系统看作一个具体的物理系统,如人的神经系统、计算机的构造系统等。进入20世纪80年代后,Newell等人又致力于SOAR系统的研究,该系统是以知识块(chunking)理论为基础,利用基于规则的记忆,获取搜索控制知识和操作符,实现通用问题求解。Minsky从心理学的角度出发,认为人们在日常的认识活动中,使用了大批从以前的经验中获取并经过整理的知识,该知识是以一种类似框架的结构存在于人脑中。因此,20世纪70年代他提出了框架知识表示方法。到80年代,Minsky认为人的智能根本不存在统一的理论。1985年,他在自己发表的著作中指出思维社会是由大量具有某种思维能力



的单元组成的复杂社会。以 McCarthy 和 Nilsson 等为代表,主张用逻辑研究人工智能,即用形式化的方法描述客观世界。逻辑学派在人工智能研究中,强调的是概念化知识表示、模型论语义、演绎推理等。McCarthy 主张任何事物都可以用统一的逻辑框架表示,在常识推理中以非单调逻辑为中心。传统的人工智能研究思路是“自上而下”,其目标是让机器模仿人,认为人脑的思维活动可以通过一些公式和规则定义,因此希望通过把人类的思维方式翻译成程序语言输入机器,使机器有朝一日产生像人类一样的思维能力。这一理论主导了早期的人工智能研究。

1977 年,第五届国际人工智能联合会议上美国斯坦福大学计算机系 Feigenbaum 教授作了关于“人工智能的艺术”(The Art of Artificial Intelligence)的讲演,提出知识工程这一名词,指出“知识工程是应用人工智能的原理与方法,对那些需要专家知识才能解决的应用难题提供求解手段,恰当地运用专家知识的获取、表达和推理过程的构成与解释,是设计基于知识的系统的重要技术问题”。

从时间上划分,知识工程的发展大体经历了三个时期,即:

(1) 大约从 1965 年至 1974 年为实验性系统时期。1965 年 Feigenbaum 教授与其他科学家合作,研制出 DENDRAL 专家系统。这是一种推断分子结构的计算机程序,该系统贮存有丰富的化学知识,其解决问题的能力达到专家水平,甚至在某些方面超过同行专家的能力,其中包括其设计者。DENDRAL 标志着专家系统的诞生。

(2) 从 1975 年至 1980 年为 MYCIN 时期。20 世纪 70 年代中期 MYCIN 专家系统研制成功,它是一种用医学诊断治疗感染性疾病的计算机程序“专家系统”。MYCIN 是规范性计算机专家系统的代表,其他许多专家系统都是在 MYCIN 的基础上研制而成的。MYCIN 不但具有较高的性能,而且具有解释和知识获取功能,可以用英语与用户对话,回答用户提出的问题,还可以在专家指导下学习医疗知识,该系统还使用了知识库的概念和不精确推理技术。MYCIN 对计算机专家系统的理论和实践都具有较大的贡献。

(3) 1980 年以来为知识工程的产品在产业部门开始应用的时期。人工智能的研究表明,专家之所以成为专家,主要在于他们拥有大量的专门知识,特别是长期从实践中总结和积累的经验技能知识。从知识工程的发展历史可以看出,知识工程是伴随着“专家系统”的研究而产生的。实际上,知识工程的焦点就是知识。知识工程领域的主要研究方向包含知识获取、知识表示和推理方法等,其研究目标是挖掘和抽取人类知识,用一定的形式加以表示,使之成为计算机可操作的对象,从而使计算机具有一定人类的智能。

## 11.2 知识分类

随着人类对于知识内涵认识的不断深入,从不同角度对知识进行了分类。从某种意义上而言,知识分类恰恰是建立在对知识内涵的理解基础上,分类原则本身也在一定程度上体现出人类在不同社会经济形态下对知识作用的不同认识。

德国哲学家马克斯·舍勒将知识划分为应用知识、学术知识和精神知识三大类。在此基础上,著名美籍经济学家弗里兹·马克卢普在 20 世纪中叶提出了知识产业理论,按照认识者的主观解释分析知识的种类,认为知识包括五个方面的内容,即实用知识、学术知识、闲谈和消遣知识、精神知识和不需要的知识(多余的知识)。另外,马克卢普还从科学的与历史



的、一般抽象的与特殊具体的、分析的与经验的、永恒的与暂时的角度,对知识类别进行了概要分析。随后,马克卢普又从世俗知识、科学知识、人文知识、社会科学知识、艺术知识、没有文字的知识(如视听艺术)等角度对知识进行分类,提出知识具有真实、美丽和优秀等性质。

随着知识经济理论的逐渐发展,经合组织(Organization of Economic Cooperation and Development, OECD)对知识的分类成为目前最具权威和流行的。根据该组织的划分标准,将知识归纳为四种类型,即事实知识(know-what)、原理知识(know-why)、技能知识(know-how)和人力知识(know-who)。以上是从知识使用的角度划分的,因而更注重知识的实践性和价值性。为了更深刻地理解知识的含义并对其进行有效管理,在 OECD 分类的基础上,进一步将知识划分为显性知识和隐性知识两大类。

所谓显性知识,是指可以通过正常的语言方式传播的知识,典型的显性知识主要是指以专利、科学发明和特殊技术等形式存在的知识,存储在书本、计算机数据库、CD ROM 中。显性知识是可以表达的、有物质载体的和可确知的。在 OECD 划分的四类知识中,关于事实和原理的知识基本属于显性知识;所谓隐性知识或称为隐含经验类知识(tacit knowledge),往往是个人或组织经过长期积累而拥有的知识,通常不易用语言表达,也不可能传播给别人或传播起来非常困难。例如技术高超的厨师或艺术家可能达到世界水平,却很难将自己的技术或技巧表达出来从而将其传播或共享。隐性知识对应的是 OECD 分类中技能知识和人力知识,其特点是不易被认识到、不易衡量其价值、不易被其他人所理解和掌握。

显性知识和隐性知识的划分突破了过去人们对于知识的认识,将还未经系统化处理的经验类知识予以承认。如果把显性知识比喻为“冰山的尖端”,则隐性知识就是隐藏在水面下的大部分,它们虽然比显性知识难发觉,却是社会财富的最主要源泉。知识管理中的一个重要观点就是隐性知识比显性知识更完善、更能创造价值、隐性知识的挖掘和利用能力,将成为个人和组织成功的关键。

### 11.3 知识表示

知识表示的最基本作用是能够清晰明确地表示面向计算机的知识。此外,知识表示还具有以下作用:

#### 1. 突显问题本质

计算机在表示事物时,为保持知识表示的紧凑和一致性,要求能抓住事物的本质和相互之间的重要区别,避免表示不必要或不可能知道的细节。所以合理的知识表示形式能突显问题的本质。

#### 2. 支持知识获取

人工智能只有不断进化,才能突显其旺盛的生命力。所以知识表示必须能支持其渐增地从外界获取知识,使计算机内部模型越来越精确地反映外部世界,更好地完成问题求解任务。

#### 3. 支持对知识库的高效搜索

如果计算机不但能够感觉到周围环境存在的问题,还能准确知道利用已拥有的知识进行解决,这对其智能行为的产生将具有重要作用。所以知识表示应能支持对知识库的高效



搜索,以便发现被感知的事物之间的关系和变化,找到对问题状态的最佳描述,消除重复、冗余的内容,处理感知信息中的错误。

知识表示研究的主要内容包括:

- 表示观的研究
- 表示方法的研究

针对知识表示观和知识表示方法,下面将分别介绍。

### 11.3.1 知识表示观

在讨论具体的知识表示方法之前,搞清楚“什么是表示”这一基本问题是十分必要的。根据对这个基本问题的不同理解和所采用的方法论,人工智能学界形成了不同的学派。

#### 1. 基于认识论的表示

基于认识论的表示认为对智能行为的刻画是与常识知识形式化紧密相关,因此对常识形式化的研究是 AI 的核心任务。常识推理在某种程度上就是问题求解中的灵活性,而灵活性的共同特点是不完全性、不一致性、不确定性及进化性,这些最终将与常识推理的可废弃性相联系。常识可以说明在自然世界中的那些“什么均可以发生,什么也可以不发生”的现象。非单调推理是认识论学派研究的主流,而对“灵活性”的不同考虑与侧重产生了对常识研究的不同理论。

基于认识论的表示主要特点是:

(1) 表示是在特定环境下对世界观察的结果,其意义在于说明表示是自然现象的一种替代形式。对人工智能研究而言,基于认识论的表示更加强调自然现象与表示之间的因果关系,即如果一种表示不能刻画某种智能行为,则失去了在 AI 范畴内研究的意义,而不管其形式是如何优美。这与物理学家的思考方法十分类似,但与数学家的完全不同。

(2) 基于认识论的表示认为启发式方法不属于表示的研究内容,其理由是对自然现象的表示是对这种现象的机制更深刻的刻画,至于怎样有效地得到行为描述与最后的合法结论不是认识世界的问题,而仅仅是怎样做得更好的问题。由于表示是对自然世界的刻画,因此从事实出发而推出结论的过程是合法的。另外,这种表示对在计算机中有效地存储的考虑并不是针对某些特定的已有表示方法,而是指由于常识知识的特点在于其存在着例外,因此需要有理论的概括才可有效地在计算机中存储它们。

综上所述,基于认识论的表示认为对常识知识的形式化是重要的任务,其含意不是指在 AI 中经常使用的穷举式的方法,而是寻找一种简洁地表示智能行为的理论。因此,这种表示的要点就可根据 P. Hayes 的解释说明为“表示的唯一作用就是携带知识”,这意味着表示可以独立于知识,当这个携带者中的变元被自然世界中的事实所代替时,知识将表现在其行为之中。

#### 2. 基于本体论的表示

基于本体论的表示认为表示是对自然世界的描述,绝对的逼真是不可能的,自然世界唯一绝对精确的表示是其自身,其他表示都不是绝对逼真,任何表示不可避免地包含着简化或人为的规定。基于这样的考虑,产生了一系列的问题,这些问题的解决就是基于本体论的表示,即:



(1) 由于任何一种表示都是对自然世界事物的近似。因此,表示必然需要对世界的某个部分给予特别的注意(聚焦),而忽略世界的另外部分(衰减),而聚焦什么和衰减什么的“聚焦—衰减”效果(心理学称这种现象为注意力集中)就是看待外部世界的规定,这形成了本体论约定的集合。本体论约定必然性的理由是表示模型的不完善,而其有效性的理由则是因为注意力集中于世界的一小部分而达到对问题的有效求解。

(2) 基于本体论的表示强调对自然世界可以采用不同的方法记述,但注重的不是语言形式,而是内容,这与基于认识论的表示“表示的唯一功能是携带知识”的观点针锋相对。但基于本体论的表示又与基于知识工程的表示不同,它所注重的“内容”不是某些特定领域的特殊的专家知识,而是自然世界中的那些具有普遍意义的一般知识(general knowledge)。寻找并建立这样一个具有常识知识并可为大多数领域使用的一般性知识库,就是基于本体论的表示中关于“内容”的含意。

(3) 基于本体论的表示认为,表示只是表述智能行为的部分理论,其暗示不考虑推理的纯粹表示是不存在的。这一观点与基于认识论的表示没有什么本质区别,区别在于表示的研究是否认为保真推理是其唯一需要遵循的原则。基于本体论的表示认为表示研究应与“启发式搜索”联系起来考虑。启发式搜索是表示理论的重要组成部分,其理由是既然表示是对自然世界不完善的描述,则保真推理就会将这种不完善带入其推出的结果中。从数学角度而言,这个推理是正确的,但它可能与自然世界的现象不符。另一个理由则可能更重要,基于本体论的表示认为合法推理可以给出问题的全部解答,但推荐推理则将给出合理的解答。在此,“合理”这一关键词有两种含意:其一指相对小的解集合,其二是指在推理过程中大大减少的搜索空间。

(4) 基于本体论的表示认为计算效率无疑是表示的核心问题之一,这是这种表示考虑“启发式搜索是表示研究不可分割一部分”的必然结论。基于本体论的表示强调启发式方法对表示的作用,这意味着有效的知识组织及领域有关的启发式知识是其提高计算效率的手段,但这一结论可能有失全面。

(5) 基于本体论的表示认为使用哪种语言作为表示形式并不是最重要的,它强调为了刻画自然世界的丰富性集成多种表示方法是必然的。另外,这种表示特别指出表示不是数据结构,这是它与基于知识工程的表示的重要区别之一。

### 3. 基于知识工程的表示

基于知识工程的表示区别于前面两种表示,主要体现在两个方面:其一是基于知识工程的表示将表示理解为一类数据结构及在其上的操作;其二是对知识的内容更强调与领域相关的、那些只适合于这个领域的、来自领域专家经验的知识。由此说明这种表示更强调其工程实现性,而不甚关心对其行为的科学解释。

综上所述,基于认识论的表示假设表示是对自然世界的描述,表示自身不显示任何智能行为,其唯一的作用是携带知识,表示研究与启发式研究无关。基于本体论的表示假设表示是对自然世界的一种近似,它规定了看待自然世界的方式,即一个约定的集合,表示只是描述了在这个世界中,观察者当前所关心的那部分,其他部分则被忽略。基于知识工程的表示认为,表示是对自然世界描述的计算机模型,应该满足计算机这一实体的具体限制。因此,表示可以理解为一类数据结构及在其上的一组操作。

不同的表示对智能模拟研究的侧重不同。例如基于知识工程的表示强调自然世界在计



计算机内部某类数据结构的映像形式及对存储内容所采用的处理方法。因此,研究知识的存储结构及其有效地使用(推理和搜索)成为这种表示研究的主要任务,这种表示侧重于“计算机可接受”这个条件。对基于认识论的表示而言,表示是一种携带知识的理论,问题求解的有效性不在其考虑之列,强调对自然现象(如常识知识)抽象、简洁的刻画。基于本体论的表示则认为任何表示均是不完全的知识理论,而对其使用的有效性(计算困难程度)则是先决条件。因此,基于本体论的表示强调一种聚焦的功能,“启发式”成为研究的一部分。

这些表示是从不同角度及不同描述层次解释表示的内涵而产生的不同结论。但是,基于本体论的表示不能因为其强调表示的不完善及可计算而否定其知识携带作用,它与基于认识论的表示的区别仅仅在于这种作用是否是唯一的。另外,由于基于本体论的表示承认表示与“启发式”研究之间的关系,因此与基于知识工程的表示紧密相关。

一般地,基于认识论的表示强调知识的某种存在性,基于本体论的表示则更多考虑知识的构造性,而基于知识工程的表示则以知识系统的可实现性作为重点。显然,对任何一门学科,存在性、构造性及可实现性都很重要,简单地否定某种表示是不合适甚至是错误的。

### 11.3.2 知识表示方法

AI中经常使用的知识表示方法几乎都是来源于研究者对智能行为在微观与宏观不同层次的观察和分析抽象出来的模型。根据表示方法的原理可以分为三类,如图11.1所示。



图 11.1 知识表示方法分类

- (1) 局部表示包括逻辑、产生式系统、语义网络、框架、脚本、过程等。
- (2) 分布表示包括基因、联接机制。
- (3) 直接表示包括各种图形、图像、声音及人造环境等。

图11.1中,局部表示是AI研究最充分也是传统AI最经常使用的表示方法,包括逻辑、产生式系统、语义网络、框架、脚本和过程等。一般地,局部表示又分为陈述性表示和过



程性表示两种。陈述性表示是对事物状态、属性和相互关系的描述；过程性表示则是对事物的行为和操作、问题的求解方法和步骤的具体描述。分布表示是对局部表示在智能行为描述上不够充分而进行的补充,包括基因、联接机制。直接表示采用与自然世界一致的表示方法,早在20世纪60年代初被提出,并引起越来越多AI研究者的关注。目前,这类表示方法称为直接表示或拟真(direct or analogical)表示,如地图、图形、图像、音乐及人造环境等。基于这类表示的系统是以对实体的拟真描述直接或间接参与推理为特点。如果考虑以计算机作为载体对知识编码,则直接表示不是一种可以完全独立于局部与分布表示的方法,主要原因是考虑到任何表示方法必须可以被计算机接受这一先决条件,因此直接表示的方法需要借助局部或分布表示的形式。对计算机而言,相对于局部和分布表示,直接表示可以视为外部表示,与其他内部表示相比,它强调表示与被表示实体之间具有结构相似性。由于这种表示方法存在的固有缺点及技术条件的限制,在较长时间内没有得到长足的发展。主要原因在于:

(1) 计算机对直接表示的信息难以处理。直接表示的信息(如图形)具有很强的领域相关性,这暗示这种表示方法包含太多冗余信息,因此注意力集中成为必须考虑的问题。另外,大多数直接表示的信息的语义取决于其使用背景,而不是独立的。这样难以发展成为一种一般性的描述语言。

(2) 直接表示难以表示定量信息,换言之直接表示描述自然世界的信息范围相对受限,这使很多研究者试图设计基于直接表示的语言均以失败告终。

下面,将简要介绍几种局部表示方法。

### 1. 产生式系统

自然界的各种知识单元之间存在着大量的因果关系,这些因果关系或者前提与结论的关系,采用产生式(或称规则)表示是非常方便的。实际上,谓词公式的蕴含关系就是产生式的特例,如“天下雨,地上湿了”。

一个产生式系统通常由三部分组成,即:

(1) 一组规则,即产生式本身。每个规则分为左部(LHS)和右部(RHS)。一般而言,左部表示情况,即什么条件发生时此产生式被调用;右部表示动作,即此产生式被调用后所做的动作。在核实左部情况时,通常采用匹配的方法,即查看当前数据基中是否存在规则左部所示的情况。如果存在则匹配成功,否则匹配不成功。匹配成功时执行右部规定的动作,动作一般是指对数据基中的数据进行某种处理,例如添加(增加新数据)、置换(替换旧数据)和删除(删除旧数据)等。

产生式是专家系统中使用最广泛的一种知识表示方法,能够模拟人类求解问题的思维方式,便于表达领域专家的启发式知识或经验知识。

产生式规则(production rule)通常用于描述事物之间的一种因果关系,其基本形式是:

$$\text{If} \langle P \rangle \text{Then} \langle Q \rangle$$

其中, $P$ 是产生式的前提,用于判断该产生式是否可用的条件,也称为前件; $Q$ 是产生式的结论或操作,用于当前提 $P$ 满足时,应该得出的结论或执行的操作,也称为后件。例如:

If 某动物吃肉 Then 它是食肉动物(表示一种结论)

If 炉温超过上限 Then 立即关闭风门,通知管理员(表示一种操作)



(2) 数据基(data base)。每个产生式系统都有一个数据基,其中存放的数据既是构成产生式的基本元素,又是产生式作用的对象。数据基常译作数据库,但这里所指的数据基和数据库管理系统中的数据库是两个不同的概念。这里数据是广义的,可以是常量、变量、多元组、谓词、表结构和图像等,往往指一个事实或断言,可以把它看成一个知识元。

(3) 解释程序。负责整个产生式系统的运行,包括规则左部和数据基的匹配,从匹配成功的规则(可能不止一个)中选出一个执行,解释执行规则右部的动作,并择机结束产生式系统的运行等。

## 2. 语义网络

语义网络(semantic network)是由 J. R. Quillian 在 1968 年研究人类联想记忆时提出的一种心理学模型,他曾提出记忆是由概念间的联系实现的,把语义网络作为人类联想记忆的一个显式心理学模型。随后, J. R. Quillian 又把它用作一种知识表示方法。1972 年,西蒙在其自然语言理解系统中也采用了语义网络表示法。1975 年 G. G. Hendrix 对全称量词的表示提出了语义网络分区技术。

语义网络是对对象及其属性分类知识编码的图形结构。语义网络是一种由结点及结点间带标记的连接弧组成的有向图,其中表示事物、对象、状态和概念等的结点有两类,三类连接弧表示结点间的关系,可用标记说明具体的语义关系。

两类结点分别是:

- (1) 由关系常量标识的结点,对应分类类别或属性。
- (2) 由对象常量标识的结点,对应领域对象。

三类连接结点的弧分别是:

- (1) 子集弧(又称 is—is a 连接)
- (2) 集合从属关系弧(又称实例连接)
- (3) 函数弧

语义网络是一种表达能力强而且灵活的知识表示方法,丰富的语义关系不但使语义网络能够方便地表示事物的属性和状态,还能恰当地表示事物之间的关系。目前,语义网络已被广泛应用于专家系统、自然语言理解等人工智能领域。

一个语义网络实例如图 11.2 所示。

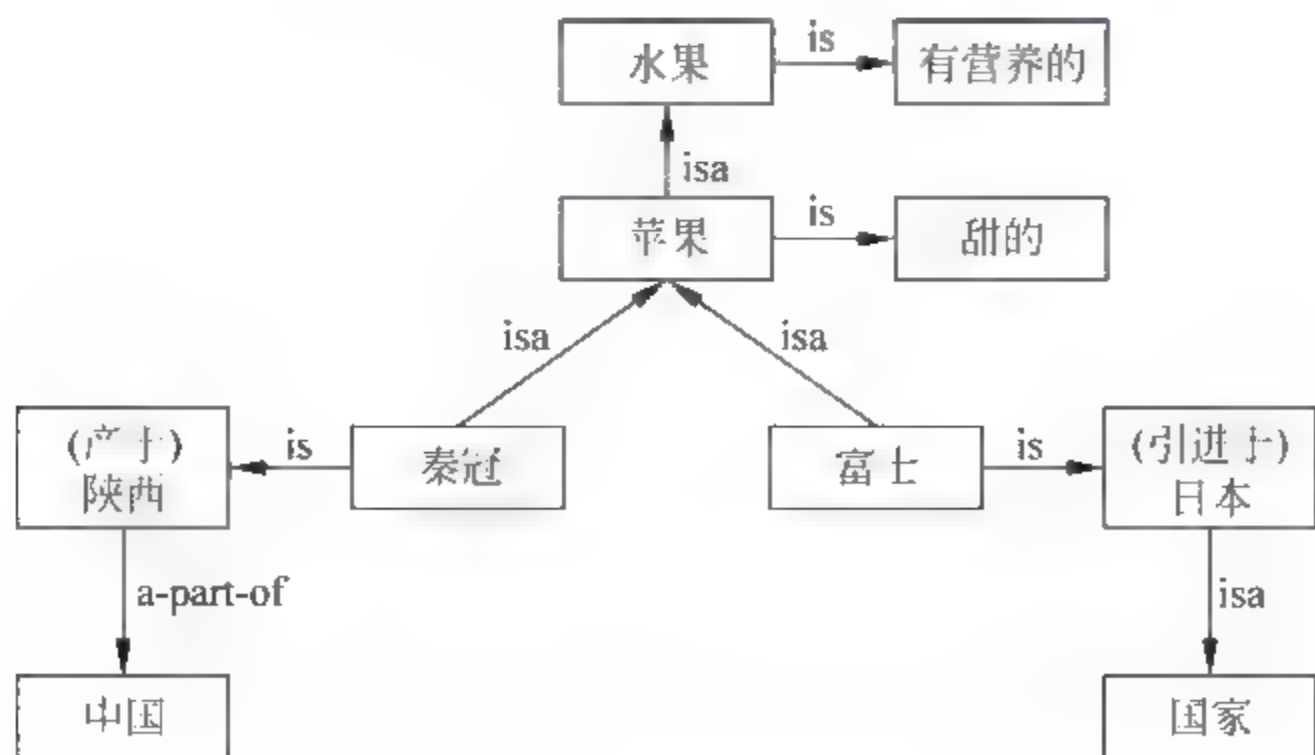


图 11.2 语义网络的实例

### 3. 概念图

概念结构(concept structure)是由美国的 John F. Sowa 提出的基于语言学、心理学和哲学为一体的一种最新知识表示方法,不但能够表示传统知识表示方法所表示的知识,而且具有表达能力强、直观、可靠性好、易于实现、接近自然语言等特点。自提出后,就在美国得到了很高的评价。

概念图的形式化定义为  $CG = (Concept\ Relation, F)$ , 其中:

- $Concept = \{c_1, c_2, \dots, c_m\}$  是概念结点(concept node)的集合。
- $Relation = \{r_1, r_2, \dots, r_l\}$  是关系结点(relation node)的集合。
- $F (Concept \times Relation) \cup (Relation \times Concept)$  是弧的集合。

概念图以图形表示是一种有向连通图,包括概念结点和概念关系结点两种。弧的方向代表概念结点和概念关系结点之间的联系。概念结点表示问题域中的一个具体或抽象的实体,概念关系结点表示概念结点之间的联系。

概念图中,概念结点用方框表示,概念关系结点用圆圈表示,有向弧标出了概念关系结点所邻接的概念结点,例如 A girl, Sue, is eating pie fast 对应的概念图如图 11.3 所示。




图 11.3 概念图的实例

此外,为了便于终端输出,还可用方括号表示概念结点,圆括号表示关系结点。概念图的这种表示形式也称为线性形式(linear form)。上面的例子采用线性形式可表示为:

```
[eat] - (agnt) - [girl: Sue]
(object) - [pie]
(manr) - [fast]
```

一个概念结点可以有两个域,其中一个称为类标号域(concept label),如上例中的 girl,类标号域表示一般的、不确定的概念;另一个为所指域(referent),如上例中的 Sue。所指域表示具体的概念,可以是一个特定的值或值的集合。实际上 referent 是 concept type 的具体值,如上例的 girl 泛指女孩,而 Sue 表示一个特定的名叫 Sue 的女孩。由此可以看出引入所指域后,概念被限定为一个确定的值。另外,概念之间具有类层次关系(type hierarchy relation),如 person 是 animal 的子类(subtype),animal 是 person 的超类(supertype)等。

例如已知概念结点的类标号集为:

```
{animal, wild-animal, pet, tiger, carnivore, feline, wild-feline, lion, jaguar}
```

其类层次关系如图 11.4 所示。

### 4. 框架

框架通常由描述事物的各个方面的槽组成,每个槽可以有若干个侧面,而每个侧面又可



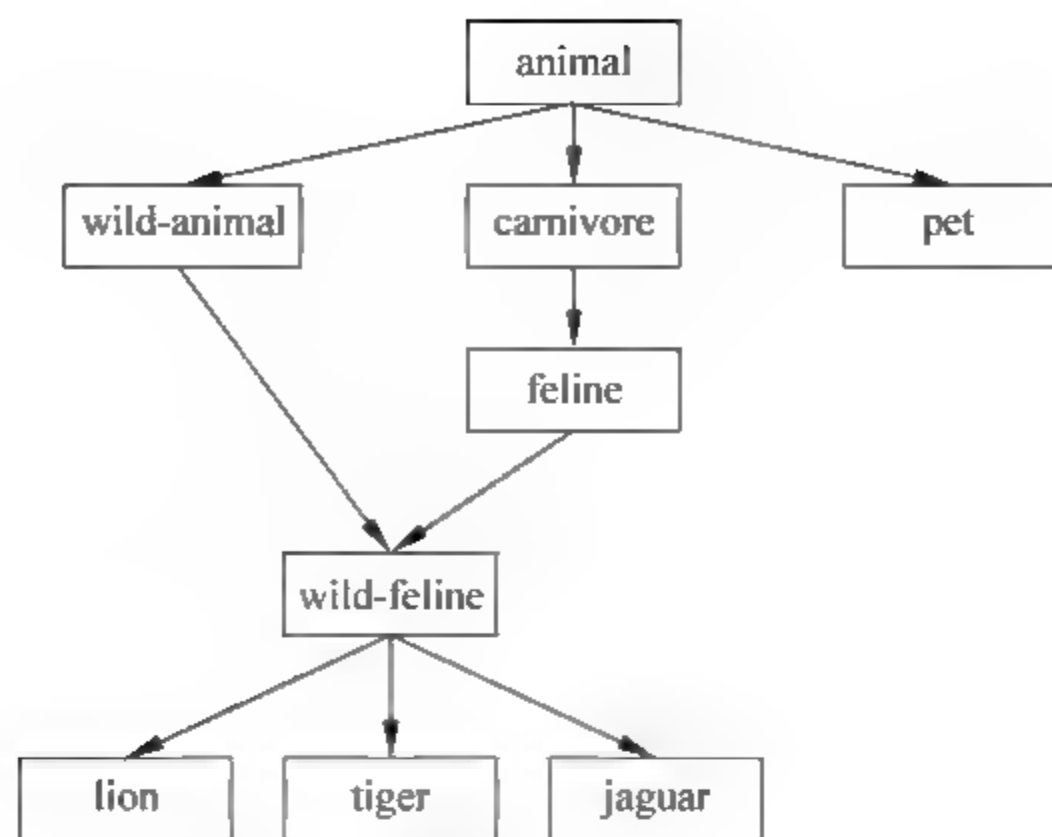


图 11.4 概念结点的类层次关系

以有若干个值。框架的一般结构是：

```

<框架名>
<槽 1> <侧面 11> <值 111>...
      <侧面 12> <值 121>...
      ...
<槽 2> <侧面 21> <值 211>...
      ⋮
<槽 n> <侧面 n1> <值 n11>...
      ⋮
      <侧面 nm> <值 nm1>...
  
```

较简单的情景是用框架表示诸如人和房子等事物。例如一个人可以用职业、身高和体重等描述,因而可以用这些项组成框架的槽。当描述一个具体的人时,再用这些项的具体值填入到相应的槽中。下面是一个描述 John 的框架的简单实例。

JOHN	Isa	PERSON
Profession		PROGRAMMER
Height		1.8m
Weight		79kg

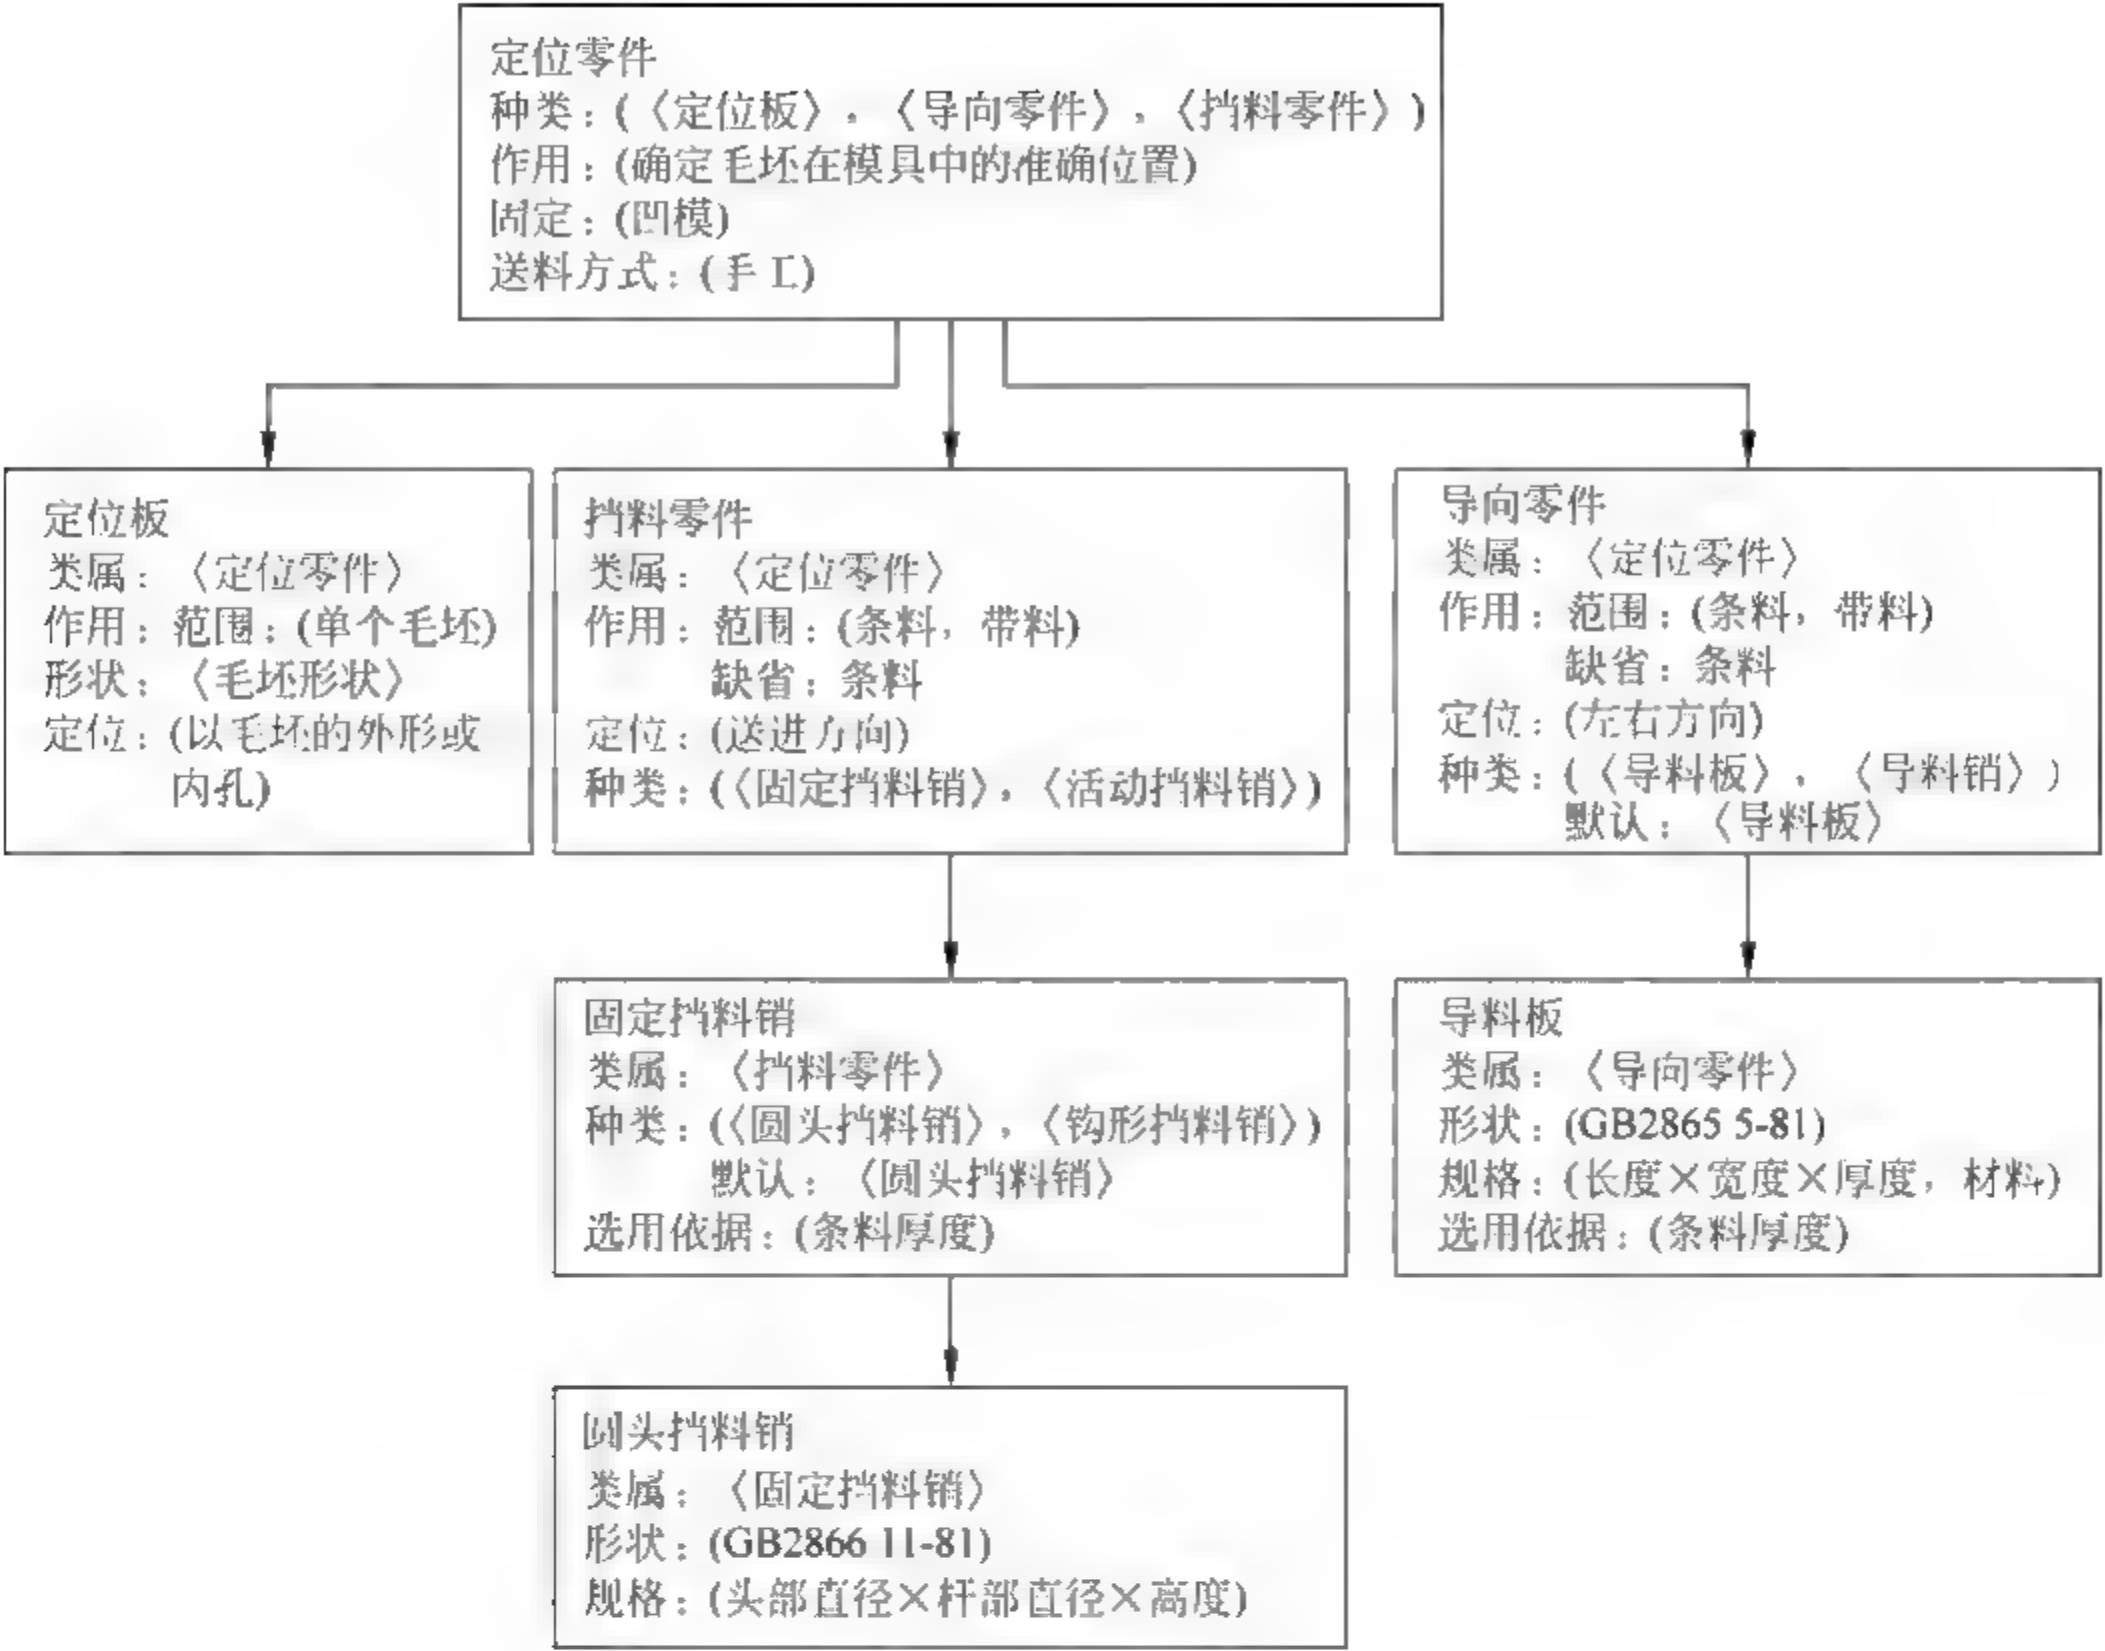
框架是一种通用的知识表示方法,对于如何运用框架还没有一种统一的形式,常常取决于各种问题的不同需要。

框架是一种复杂结构的语义网络。因此语义网络推理中的匹配和特性继承在框架中也可以使用。此外,由于框架用于描述具有固定格式的事物、动作和事件,因此可以在新情况下,推论出未被观察到的事实。

框架包含所描述的情况或物体的多方面信息,包含物体必须具有的属性。在填充框架的各个槽时,要用到这些属性。框架描述它们所代表的概念的典型实例。

图 11.5 给出一个定位零件源框架。

用一个框架具体体现一个特定情况的过程,经常不是很顺利。当这一过程遇到障碍时,可以不放弃原来的努力去从头开始,有很多办法可供参考。



- (1) 选择和当前情况相对应的当前框架片断,并把这一框架片断和候补框架进行匹配,选择最佳匹配。
- (2) 尽管当前框架和需求描述的情况之间存在不相匹配的地方,但仍然可以继续应用这一框架。
- (3) 查询框架之间专门保存的链,以提出应朝哪个方向进行试探的建议。
- (4) 沿着框架系统排列的层次结构向上移动(如从狗框架→哺乳动物框架→动物框架),直到找到一个足够通用,并且不与已有事实矛盾的框架。

11.4 知识管理

11.4.1 概述

当智能的人类与知识共同出现在这个世界时,一种对于知识的操作就此产生,即知识的管理与共享。知识管理与共享是人类社会进步和文明继承发展的必要条件。通过知识获得、交流和共享,可使人类在知识获取的过程中,避免重复工作和相同的错误。即使在现代知识型组织中,关于如何可以达到期望结果和避免犯错误的最重要的思想和理论主要是储



存在人们的大脑中,而不是在计算机或书籍中。

伴随着知识经济的萌芽,知识管理备受关注。但是,就像人们对知识有不同的理解一样,以知识和人为管理对象的知识管理,目前也没有一个广泛认同的定义。

按照美国戴尔集团创始人之一卡尔·弗拉保罗的说法“知识管理就是运用集体智慧提高应变和创新能力”,是为企业实现显性知识和隐性知识共享提供的新途径。

美国“知识的进化”作者 Verna Allee 对知识管理的定义是“帮助人们对拥有的知识进行反思,帮助发展支持人们进行知识交流的技术和企业内部结构,并帮助人们获得知识来源,促使他们之间进行知识的交流。”

Daniel E·O'Leary 认为“知识管理是将组织可得到的各种来源的信息转化为知识,并将知识与人联系起来的过程。知识管理是对知识进行正式的管理,以便于知识的产生,获取和重新利用”。这种解释着重阐明信息、知识和人在知识管理过程中的不同角色。

Wiig 指出知识管理主要涉及四个方面:自上而下检测和推动与知识有关的活动,创造和维护知识基础设施,更新组织和转换知识资产,使用知识以提高其价值。

知识管理的目标主要包括六个方面,即:

- 知识的发布,以使一个组织内的所有成员都能应用知识
- 确保知识在需要时是可得
- 推进新知识的有效开发
- 支持从外部获取知识
- 确保知识、新知识在组织的扩散
- 确保组织内部的人知道所需的知识在何处

尽管上述定义对知识管理的理解不尽相同,但都隐含了知识管理的三个基本要素,即知识生产过程管理,知识传播过程管理和知识使用过程管理。因此,知识管理是对知识的生产、传播和使用的全程监控。它以信息技术为基础,为知识的生产、传播和使用提供开放的可管理的协同工作机制。

#### 11.4.2 知识管理与信息管理的关系

知识与信息、知识管理与信息管理是紧密相关的。信息是事物运动的状态及其变化的方式,信息有时与主体有关。而知识是客观的,与主体无关。知识是信息,是信息的提炼和一般化,然而信息不一定是知识。

信息管理是为实现组织目标、满足组织需求而对信息资源进行规划、开发、集成和利用。在知识管理与信息管理的关系方面,信息管理是知识管理的基础,知识管理是信息管理的拓展和延伸。信息管理和知识管理之间的区别体现在以下几个方面。

首先,知识管理拓展了信息管理的管理对象。知识管理的对象包括知识以及传统意义上知识的创造者——人,而信息管理仅仅局限于用语言、文字、图形、图像和声音等各种载体表示的信息。因为知识存在于人的头脑,所以只有人能够充当知识创造的主体,尽管计算机具有强大的信息处理能力,它只能是知识创造的辅助工具。因此,知识管理把人纳入了其管理的范畴。

其次,知识管理提升了信息管理的地位和作用。信息管理服务于组织的生产、经营和管



理。信息管理系统是为组织整体的管理、控制和决策等服务,它的成功运行可以保证组织运作的高效率、及时性和适应性。在知识型组织中,知识的生产、传播和利用是组织的主要工作之一,是组织核心竞争力的综合体现,是组织在激烈的全球竞争环境中制胜的法宝。知识管理不仅仅是人与人之间的知识共享,还包括知识的创造和广泛利用。创造知识的增值价值和增值服务是知识管理的目的,也是其备受青睐的原因所在。

再次,知识管理强化了对信息管理基础设施的要求。特别是在知识传播方面,要求做到任何时间,任何地点,任何人都可以获得所需要的知识,以保证知识服务的实时性和高效性。

最后,知识管理是与信息技术、人工智能、管理科学、人文科学和经济学等相关的交叉学科。知识管理研究人和知识在知识型组织中的地位和作用,研究人类产生知识的机制,以及信息技术如何被用来提供知识生产、流通和使用的支撑环境。知识管理还研究知识如何有效组织、存储和处理,以协助乃至代替人类使用和创造知识。与之相比,目前的信息管理在相当程度上还属于计算机应用的范畴。

### 11.4.3 核心技术

知识管理实现两个基本目标:一是已有知识的共享与重用;二是创造新知识。这是跨越某一时段的实践过程,与人、商业应用和信息技术密不可分。

知识管理包括以下方面:

- 知识聚集:包括已有知识的集成和新知识的获取。知识聚集又称为知识生产。
- 知识组织和存储:给获得的知识赋予一种结构并合理地存储,以便有效管理和使用。
- 知识演变:由于知识聚集过程中发生的偏差,以及知识的时变性,需要更正、更新,删除旧知识,增加新知识。
- 知识传播:使需要知识的任何个人和组织可以在任何时间、任何地点获得知识。
- 知识使用:在知识处理系统之间和相关人员之间实现知识共享和重用。

知识管理离不开知识管理系统的支撑。知识管理系统不是一个单纯的知识发布系统,而是一个交互式的开放的协同工作环境。知识管理涉及许多核心技术,主要包括:

#### 1. 信息技术

与互联网、电话网和电视网等相关的信息技术主要用于解决知识的快速、高效、实时和准确传输,是知识传播的基础设施。知识传播是集语言、文字、图像和声音于一体的多媒体数据传输,信息技术的快速发展为这种多媒体数据的快速、实时和准确传递创造了条件。

#### 2. Web 技术

目前,Web 技术及其多层体系结构是知识管理系统普遍采用的技术。Web 技术主要涉及两类标准,一个是应用层协议,如超文本传送协议(HyperText Transfer Protocol, HTTP);另一个是表示层句法,包括超文本标记(HyperText Markup Language, HTML)和扩展标记语言(Extensible Markup Language, XML)。此外,动态页面技术可以使得用户能够访问存储在 Web 中的实时数据。

#### 3. 知识存储技术

知识管理需要管理的知识量非常大,这些知识需要有效地组织和存储。为了使知识能



够更好地共享和重用,知识和知识处理系统应该分离,知识应该独立于知识处理系统。而且,知识通常是比较稳定的,更新的速度较慢。因此,知识库的知识时限达到几年甚至几十年。并且,知识库面对的主要问题不是查询,而是知识的分析和处理。所以,与事务数据库相比,数据仓库更适合用来存储知识。

另外,越来越多的知识以 HTML 和 XML 文件的形式存储在 Web 服务器中,这给知识存储提供了新途径。

#### 4. 知识获取技术

Feigenbaum 教授曾说知识获取是人工智能中最重要的核心问题,是人工智能研究的关键。知识获取是指从纷繁的信息中发现、提取和挖掘知识。知识获取可以分为人工获取、机器辅助的人工获取和机器自动获取三种类型。就目前的技术发展而言,机器辅助的人工获取既能保证一定的精度,又能确保较高的效率,而知识的机器自动获取是人工智能追求的目标。

机器学习是机器获取知识的主要方法,而数据挖掘和 Web 挖掘是机器学习的重要研究方向。

数据挖掘又称为数据库中的知识发现(Knowledge Discovery in Database, KDD),是从大量原始数据中挖掘出有用的、潜在的信息和知识(如概念、规律、规则、限制、模式、约束)。数据挖掘方法众多,如利用 ID3 和 C4.5 等信息论方法;粗糙集和覆盖方法等集合论方法;神经网络和遗传算法等仿生方法、统计分析方法等。数据挖掘的成功应用是联机分析处理,利用原本为统计而搜集的数据发现各种模式,分析变化趋势进行预测,以及支持决策。

Web 内容挖掘、Web 结构挖掘和 Web 使用挖掘是 Web 挖掘的三个组成部分。Web 内容挖掘通常指 Web 文本挖掘。

#### 5. 知识表示与本体

知识是知识管理的管理对象之一,是人类认识客观世界的创造性成果,供人类学习使用。因此,知识构成人类思维活动的环境,是人类创造性工作的基石。

机器要加工和处理知识首先必须有知识,因此,一个关键问题是机器如何表示知识。就好像人类创造了语言文字,使知识可以保存记录,这些知识既是人类创造的成果,又是后人学习和再创造的基础,知识表示就是机器描述知识的语言和文字。

构建智能系统的一个新方法是聚集可重用构件。今天建造基于知识的系统通常必须从头开始建立知识库,其实可以通过聚集可重用构件完成。系统开发人员只需创建与其系统任务相关的特定知识和推理机。新的系统将和已有系统进行互操作,利用它们执行某些推理。通过这种方式,知识、问题求解技术和推理服务可以在系统之间共享。这种方法有利于方便地建立更大和更好的系统。然而时至今日这一设想还远未实现,其中一个重要原因就是知识不能共享与重用。

Angus 等指出目前的知识管理不能重用从经历中获得的知识,因为它不以一种形式化的方式共享。知识的共享与重用是知识管理的实现目标之一。可见,知识共享与重用不仅是构建智能系统的普遍性问题,更是知识管理面临的严峻挑战。知识共享与重用需要一种形式化的共享的知识表示规范,尤其是现在的知识管理系统乃至智能系统都是分布式系统,集中式知识表示已经不能满足应用的需要,必须研究知识的分布式表示方法。知识表示的

基础是本体(ontology),它是共享知识表示的关键。

为什么说本体是共享知识表示的关键呢?原因在于:首先,本体阐述了知识的结构。给定一个领域,构成了面向这一领域的知识表示系统的核心。没有知识之下的本体或领域概念化,就没有一个表示知识的词汇。其次,本体使知识共享成为可能。因为有了本体,就不必重复知识分析过程,而可以与他人共享这一知识表示语言。共享本体形成了领域相关的知识表示语言的基础。基于本体构造的知识表示语言是内容丰富(或语义丰富)的,它们有大量包含复杂领域内容的项,这类共享将大大增加知识重用的潜力。

建立可以共享与重用的领域本体不仅是知识表示的需要,也是实现知识共享和重用的关键,是实施知识管理的一项基础工作。



## 第 12 章 语义网和本体

### 12.1 语义网

1990 年 Tim Berners Lee 发明了万维网,旨在通过 Internet 获取各种信息。二十多年过去了,万维网发展飞速,从最初被动地发布数据,到交互式地获取所需数据,到现在实现智能检索,即根据用户需求获取信息。现有的检索工具,如 Google 已经把检索范围和搜索速度提升到前所未有的程度。然而,人们发现万维网还是无法满足日益丰富多样的需求,其局限性体现在:

- (1) 信息是海量的,但缺乏对信息的描述,即缺乏元数据(metadata);
- (2) 万维网的基石——HTML 提供的链接缺乏语义;
- (3) 基于关键词检索的万维网搜索引擎的检索质量和效果不尽人意。

2000 年 12 月在 XML2000 会议上, Tim Berners Lee 提出了下一代 Internet 的概念——语义网(Semantic Web),为人们描绘了未来语义网的美好前景。语义网是当前万维网的扩展和延伸。语义网的信息具有充分、完备的语义定义,能够在人与计算机之间建立语义上的理解与合作。因此,语义网是具有语义的万维网,是能够理解语义的万维网。

#### 12.1.1 概述

语义网研究的重点是如何把信息表示为计算机能够理解和处理的形式,即带有语义。语义网中语义是核心,即能够在人与计算机之间、计算机与计算机之间以无偏差的方式传递信息。语义网的基本思想是对互联网上的任意资源,进行结构化的描述并引入语义,使得计算机可以理解互联网上的信息。当然,计算机不可能真正像人一样进行思考,但是通过制定标准,使用标准描述信息的含义,计算机就可以根据标准进行自动分析和推理,将网络服务集成在一起,使自动化智能服务成为可能。语义网是通过在互联网上提供定义好的、相互链接的数据,让互联网数据能被高效、自动地发掘利用、不同的数据能更好地集成,而且能被各种不同的应用程序使用。

语义网提供一个基础架构,通过这一架构在 Internet 上不再只能处理 Web 页面,数据库、Web 服务和程序,传感器、个人智能设备甚至家用电器设备都能通过网页来传递并处理数据。各种软件代理能够搜索并过滤这些数据,以一种全新的令人激动的方式把这些处理好的数据送到 Web 使用者面前。

回想一下 Internet 刚普及时的文档处理系统,检索并引用远程系统的信息还是专家们的游戏。虽然 Internet 可使用户很方便地登录到远程系统,然而这些系统往往使用不同的信息提取协议,例如通过 Telnet 登录到一个远程系统后,在获取信息之前用户需要首先了解该系统的信息提取协议,而且找到所需信息后,要先复制到用户的剪贴板,然后再拷贝(或者重新输入)到自己的文档中。采用上述方式对于处理那些关联性强、时效性和准确度要求



极高的文档简直就是一场噩梦。

使用 Web 技术,能轻松实现信息间的无缝链接,尽管很多系统的 Web 服务器运行在不同的机器上,Web 应用程序之间传递内容仍然很困难。目前,在充分利用 Web 方面仍然受到很多束缚。假设用户在浏览 Internet 时偶然打开了一个会议通知,Web 上有召开会议的时间和地点,并且还有很多超链接地址,分别链接到本次会议召集人及其他参与人员的个人主页。当用户报名参加本次会议,开始点击注册按钮,此刻期待着电子日历能自动记录会议的日期和时间,并能链接到 Web 上的详细说明,希望数字电话能下载会场地址并计算出在会议当天到达的最佳列车路线;还希望随身携带的商务通能自动把参会人员的联系方式下载并临时保存起来,直到会议结束。用户是多么希望上述处理能够在 Web 上一次点击即全部自动完成。

遗憾的是,现在还无法做到。事实上用户不得不非常辛苦地把会议详细情况逐条复制并粘贴到地址簿,自己查找会议日期和时间,不得不手工从各个会议参加者的个人主页中寻找并拷贝其联系信息到地址本中,手动调整其地址和电话号码格式,还不得不在手机上录入会议的位置信息。以上描述的情形还只是个人在网络上处理数据所遇到的麻烦,处理企业业务数据时的困难更是可想而知。如果用户试图连接公司内部运行的不同的数据处理系统,或者试图帮助客户从多种数据库中整合所需的信息,可能会遇到非常尴尬的情形。在库存管理系统和财务系统中存在很多重叠的数据,在整合这两个系统的数据时很容易发生主键冲突或者数据关联错误,可能不得不使用程序员编写的接口程序从库存管理系统中筛选并格式化数据,然后导入到财务管理系统。同时还发现企业的客户关系管理系统也应该和订单管理同步进行数据整合,否则将会严重影响公司的业务和生产。如果公司存在很多不同的应用系统,将需要编写大量代码提供各种数据接口,这无疑会带来高昂的程序维护开销。

使用 XML 对于改善上述情况将有所帮助,如果所有的应用程序都采用 XML 格式,程序员只要学会处理 XML 数据,就不必和各种离奇古怪的数据格式打交道。这意味着可以利用一些 XML 工具如 XSLT(一种转换语言,参见 <http://www.w3.org/TR/xslt>)粘合应用程序。遗憾的是,这种技术还无助于彻底改善数据接口的效率。因为每一对应用程序之间,甚至同一对应用程序的每一种接口之间,都需要定制相应的 XML 到 XML 桥。换言之,在不同的应用程序之间提取 XML 文件时,不是简单地进行合并。为了执行针对 XML 文件的查询,还需针对其配对文件补充特定的限制条件,不是简单地把两个查询合并到一起。这与关系数据库中通用的数据元能被轻松地连接到一起的处理方式大不相同。

但是,不同的数据库由不同的 schema(数据视图)文件架构而成,而且这些 schema 的表达并不清晰。因此,仅靠 XML 标记很难直接和另一个数据库中的域关联。解决办法之一是把一些 schema 变得更明白易懂,并映射为统一的术语。XML Schema 语言(<http://www.w3.org/XML/schema>)允许很多公益组织整理出统一的 schema 文件。一个公司甚至是一个特定的商业部门,通过开发一个统一的 XML 映射集(例如一个特定的 schema 文件)就能采用统一结构表达信息。实际中,实施起来并不容易,而且针对不同用户开发一个大型词汇表是非常棘手的事情。

不同结构的 schema 文件以及基于不同商业词汇的不同用户的 schema 文件之间的映射,都不是 XML schema 所能解决的问题。实际中经常需要处理异构数据的映射问题,为



此需要寻求更为有效的数据表达工具。例如关系数据库中的关系演算,数据表达能力远远胜过许多旧的数据库(文件数据库),因此它成了过去处理数据映射的标准。更为有效的表达方法,如实体关系或者对象模型,可以解决复杂的数据映射或异构数据查询。总之,采用更有表现力的语言能提升协同工作的层次。既然以前的数据系统采用关系模型很好地解决了数据兼容问题,所以非结构化的 Web 数据或 XML-schema 定义,也可以通过关系模型有效解决数据模型问题。

为此,建立了一个名为资源描述框架(Resource Description Framework, RDF, 参见 <http://www.w3.org/RDF/>)的语义网基础组件。如果两份来自不同数据源的 RDF 格式文件需要合并,只需要将其合并成一个大文件,即把文件中的关键字进行简单的连接。因为 RDF 文件格式的关键字均采用相同的通用资源定位符(Uniform Resource Identifier, URI)。如果想在合并后的 RDF 文件中增加限制条件,修改原来的查询方式,只需要直接在新的 RDF 文件中增加限制条件即可。XML 文件是由元件和属性组成的,只能告诉我们文件里面记录了什么内容,而 RDF 则由一段段数据表达式组成,每个表达式都描述了一个特定的值,这个值相对于一个数据库表的单元。原有的关系数据库运算都可兼容,如连接和视图等,并可以使用常用工具加以执行。

这样可以顺利地解决企业级应用系统间的数据集成问题。只要把每个应用程序的数据输出转换为 RDF 格式文件,就可以针对 RDF 执行各种查询,轻松地编写并修改查询条件,导出所需数据。反之,这些数据也能轻松地导入到其他应用程序中。而且,这种问题和系统规模只是线性相关,就好像添加新的 Web 服务器不会影响到其他人浏览 Web 一样,新的 RDF 也能被轻松地添加到 Internet 上,而不会影响正常使用。大量需要人工编写的数据接口奇迹般地消失了,就像文档之间可以链接一样,数据也能通过 Web 连接在一起。

正如如果没有 RDF 就难以在 Internet 上整合数据库一样,应用程序的跨互联网整合也遇到了同样问题。表面上看,在 Internet 上整合应用程序是很容易的,经常是轻轻点击一下就从 Internet 下载 java 或 flash 程序到本地运行。但这对于电子商务应用程序是无效的,特别是在 B2B(Business to Business)的应用程序之间。

设想某个企业想从一个供应商那购置一批零部件,需要先联系大型船运公司安排船运,然后从本地几个生产商中精心挑选一家在零件运到时具备最高生产能力的厂家生产。而且是希望能通过 Web 高效地解决这一问题,即由一个销售员下订单,然后启动整个供应链高效协同工作。这看上去和前面提及的数据库间整合有几分相似,然后却要复杂得多。因为牵涉到的各家企业采用的内部管理软件可能完全不同,而不仅仅是数据库的不一致。更糟的是,这些应用程序可能运行在企业内部某台特定用途的计算机上或隐身在内部防火墙和安全防护设备后面。首要解决的问题就是如何能通过 Internet 把这些不同的应用程序集成起来,也就是要为这些程序提供通信协议可以理解的服务描述书。很多 IT 企业一直致力于解决这一难题,从而形成了一个正快速增长的 Web 服务市场,这也是现代电子商务中增长最快的业务。例如著名的 B2C(Business to Customer)电子商务组织 Gartner 声称“采用 Web 服务将降低成本,将 IT 项目的效率提高 30%。估计 Web 服务业已形成了十多亿美元的市场规模,并正在迅速成长。”

所以,正加速开发新的协议和语言以标准化描述 Web 服务。目前,开发了一种基于 XML 的 SOAP(Simple Object Access Protocol,简单对象访问协议)(<http://www.w3.org/TR/>



SOAP)协议为 Web 服务之间提供基于互联网的标准调用方法。此外,正在抓紧研发新的 Web 服务描述方法和 Web 服务架构语言,这也是 W3C(World Wide Web Consortium)当前的主要任务。

语义网将在广泛分发 Web 服务时提升 Web 服务的作用。许多 Web 服务供应商希望通过 Internet 在更大范围内为不同用户共享他们的服务,提供中间代理服务即一种让 Web 服务能在用户间自动匹配的能力是非常困难的。而且,这种周而复始的同类词汇间的映射会导致数据库的暴露。使用现有的实现方法,Web 服务描述了输入、输出、端口和其他调用概要,但是服务的行为描述却以一个 content(内容)字段保留下来,等待着将来的描述。因此,这个问题就和前面的数据库间整合非常相似,不同企业用户间未经商定的不同映射等待着被解析。在预先分派好的团体用户里面还有达成一致的可能,但那些外来的 Web 服务提供商,由于使用了不同的内容 schema,要统一建立映射关系就非常困难,这要求我们在整个供应链上进行大量的预先约定,而这将大大限制 Web 服务的应用范围。

对此,强大的语义网表达语言能够提供帮助。RDF 的扩展,即 RDF schema 以及一种新研发的 Web 本体语言 OWL(Web Ontology Language,参见 <http://www.w3.org/2001/sw/WebOnt/>),能够建立层级和词库,帮助解释词汇之间是如何关联的。例如,已在互联网上建立一个说明运送事件的 schema,邮寄是一种运输,加急邮件是一种邮政,等等。通过合并不同的词汇表描述的服务项目可以轻松整合出新的服务,而且被合并的文件仍然是合法的 RDF。

此外,并不要求建立服务连接的描述信息采用自然语言中的公用词汇。不管外部服务是来自不同的用户还是开发者,是来自一个不同的词典还是随机在 Internet 上发现的某个 Web,都能解释映射信息。因此,只需将名为 lorry 的合作者和 truck 之间建立对应关系,以后当合并图表时,可以发现 lorry 与 truck 的联系。甚至,这种新的语言还允许执行更为复杂的映射和合并,例如如果把 Nissan-Maxima 定义为豪华型汽车,产地是日本,当我们连接到尼桑经销商的服务时,即可找到上面定义的属性。

当某些相对复杂的服务不能很快从 Internet 获得时,语义网将能提升现有 Web 服务的能力。例如一家专门提供小糖果礼品盒的公司需要同时订购 100 个心形巧克力和 200 个棒棒糖,并需要把它们运送到北京进行包装,找到心形巧克力供应商、棒棒糖生产厂家甚至很多的运输企业并不难,但这不是仅通过一个服务能够解决的。显然我们希望能把上述几个服务打包在一起而不必去辛苦寻找三个以上的 Web 服务。语义网允许把所需的服务轻松地整合起来,即便事先没有采用同样的词汇进行服务定义。语义网的应用程序还能分析实现目标的方法,提供高效、合理的 Web 服务集成(例如巧克力需要冷藏,能自动添加该项服务申请以保证巧克力不会在运输过程中溶化)。尽管复杂的 Web 服务组合仍是一个尚在研究的课题,但许多基本的 Web 服务装配,如各种不同服务的输入和输出匹配已经可以通过现有的语义网工具成熟应用了。

或许,曾有人担心建立语义网是在从事一项面向未来和火箭科学家们一样困难的工作,但事实并非如此。语义网正如万维网一样,只要拥有明确的设想就可以在 Internet 上轻松实现。只是把很多众所周知的成熟技术带到 Internet 上,让不同的数据和应用程序能通过 Web 自动集成,以消除以前需要复杂的人为干预才能协调工作的麻烦。



### 12.1.2 层次结构

语义网构建在自定义标记的 XML 和数据表示灵活的 RDF 基础上,旨在应用有效的标准和技术使计算机能够更多地理解 Web 信息,从而实现知识发现、数据集成和信息导航等,并将特定的信息添加到万维网上辅助服务的自动化。

语义网的层次结构如图 12.1 所示,自底向上依次为 Unicode(统一字符编码)和 URI、XML、RDF 和 RDF Schema(RDFS)、本体(Ontology)、逻辑(Logic)、证明(Proof)和信任(Trust)。在语义网的七层结构中,XML、RDF 和 Ontology 三层是核心和关键,主要用于表示 Web 信息的语义。经过长期的研究和发展,这三层已较为成熟,推出并形成了一系列的成果和标准,而证明层正处于探索之中。

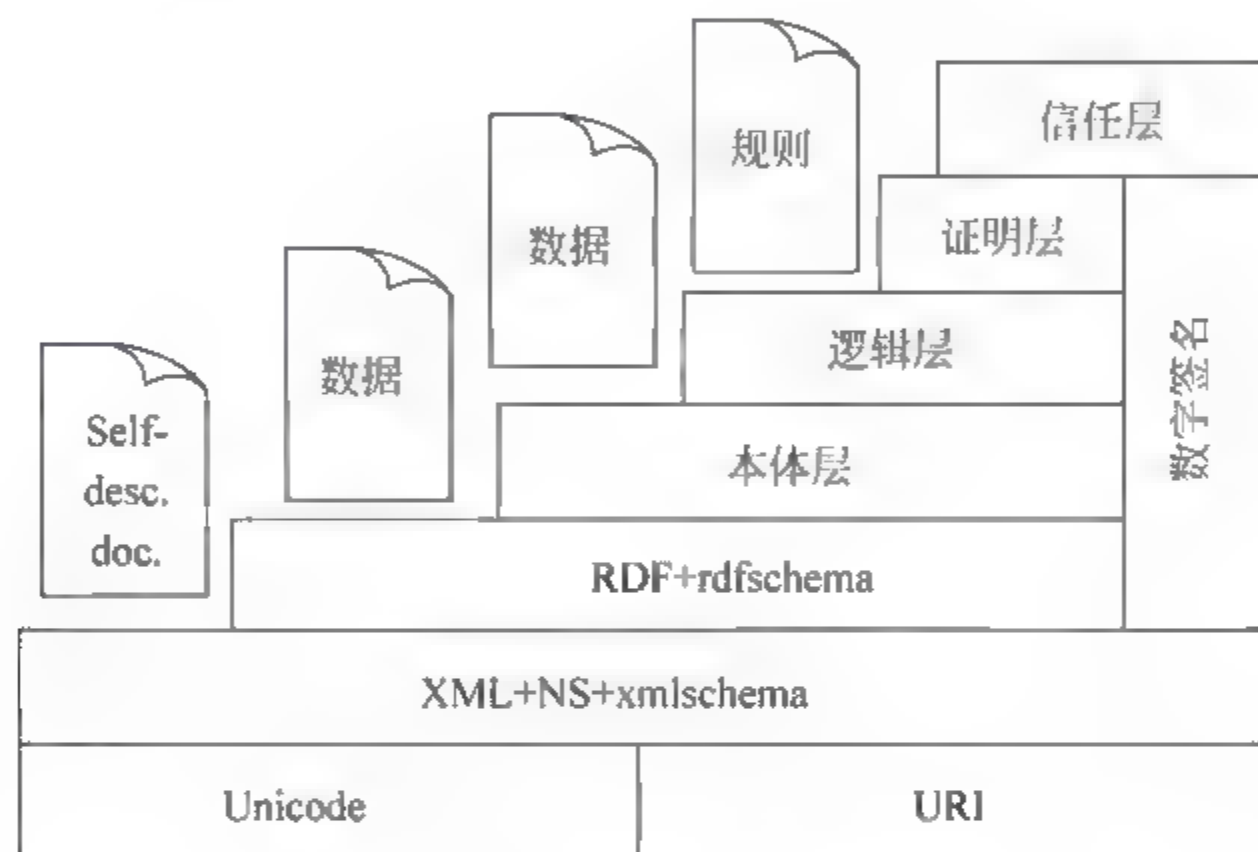


图 12.1 语义网的层次结构

此外,数字签名位于层次模型的右侧,贯穿了语义网的中间四层。数字签名是一种基于 Internet 的安全认证机制,用来检测文档是否被篡改,以证实其可靠性。当信息从一个层次传递到另一个层次时,可以使用数字签名说明信息的来源和安全性。这样,接收方可以通过数字签名鉴别其来源和安全性,决定信息的可信任程度。有了数字签名一些重要的电子商务活动就可在语义网上安全地进行。其实不仅对于语义网,对于所有的信息交换系统数字签名都非常重要。

#### 1. Unicode 和 URI 层

Unicode 和 URI 是整个语义网的基础,其中 Unicode 负责资源的编码,URI 负责资源的标识。

Unicode 是一个字符集,该字符集中所有的字符都用两个字节表示,可以表示 65536 个字符,基本上包括了世界上所有语言的字符。语义网的最终目标是构建一个全球信息网络,必然涵盖各个国家和民族的语言,采用 Unicode 作为其字符编码方案,可以从根本上解决跨地区、跨语言字符编码的格式标准问题。

URI 是语义网的根基。同 Internet 使用 URL(Universal Resource Locator,统一资源定位符)标识 HTML 页面一样,语义网同样需要一个类似的规范,唯一标识网络资源。语



义网所使用的 URI 规范在 RFC 2396 里进行了详细说明。任何组织和个人都可以自由定义和使用 URI。值得注意的是,URI 与 URL 区别很大。URL 用来标识网络路径,可以通过 Internet 在 URL 上访问到相应的资源;但一个 URI 标识的资源可能根本无法通过网络访问到,URI 标识仅仅标识一个资源,并不同时包含该资源的访问路径。URI 包含 URL,URL 是 URI 的超集,URI 支持语义网的对象和资源的精细标识,使精确信息检索成为可能。

## 2. XML、Name Space 和 XML Schema

XML 已经成为数据表示和数据交换的事实标准,提供一种格式自由的语法,用户可以按照自己的需要创建标记集,并使用这些标记编写 XML 文档。正因为任何人都可以自由定义标记,所以不可避免地会发生标记同名的情况。W3C 引入命名空间(namespaces)机制,即在标记前面加上 URI 索引,以消解这种冲突。XML Schema 提供了一种对 XML 文档进行数据校验的机制,基于 XML 语法提供多种数据类型,对 XML 标记的结构和使用方法进行了规范。XML Query 是在 XML 基础上发展起来的技术标准,类似的还有 XPath 等,使用这些技术可以对 XML 文档进行数据检索、提取结点等操作。

然而,随着 XML 在数据交换和应用集成等领域的广泛应用,人们逐渐发现 XML 仅适用于表示数据的语法,却不能涵盖数据的语义。鉴于 XML 受到业界的普遍支持,并且已经具备了较完备的技术标准,在语义网的体系框架中将其作为数据表示的语法层。

## 3. RDF 和 RDF Schema 层

XML 不适于表达数据的语义,因此数据的语义定义和互操作需要由更高一层完成。因此,W3C 组织开发了一种新的语言以描述 Internet 的资源及其关系,即资源描述框架(Resource Description Framework,RDF)。RDF 采用三元组又称为陈述(statement),表示互联网的资源、属性和值。三元组由主体(subject)、谓词(predicate)和客体(object)组成,分别对应陈述中的资源、属性和值。RDF 提供了一套标准的数据语义描述规范,但它还需要定义描述中使用的词汇。RDF Schema(RDFS)提供了一种面向计算机可理解的词汇定义,提供了描述类和属性的能力。RDFS 在 RDF 的基础上引入类、类之间的关系、属性之间的关系以及属性的定义域与值域等。如同一部字典,计算机通过它可以理解数据的含义。RDFS 明显区别于对象模型的是属性独立于类,一个属性可以应用于多个类或实例。

RDF 构建了一套完整的语法以便于计算机自动分析和处理,包括三种常用的表示方法,即图形、N3 和 XML。其中,图形表示是对 RDF 模型的直接描述,可以直接明了地观察 RDF 数据及其关系;N3 是一种三元组的方式,通过枚举 RDF 模型中的每个陈述表述 RDF 模型,最易使用,简明易懂;RDF/XML 将 RDF 以 XML 语法描述,将 XML 的解析和解释过程结合。这样 RDF 在帮助解析器阅读 XML 的同时,可以获取 XML 表达的语义,并可以根据其关系进行推理,从而做出基于语义的判断。但是 RDF/XML 常常因为过于复杂而难以使用。

该层用于描述万维网的资源及其类型,为 Web 资源描述提供一种通用框架和实现数据集成的元数据方案。最底层的 URI 标识 Web 对象,RDF 和 RDFS 层则可对 URI 标识的对象进行陈述。

## 4. 本体层

本体层用于描述各种资源之间的联系,本体揭示了资源本身及资源之间更为复杂和丰



富的语义,从而将信息的结构和内容分离,对信息进行完全形式化的描述,使 Web 信息具有计算机可理解的语义。因为本体定义了不同概念间的关系,所以本体层能够对字典(或词汇)的演化提供支持。

作为语义网中最为核心的一层,本体层在 RDF 和 RDFS 进行基本的类/属性描述的基础上,更进一步地描述本体及其关系。这一层具有专用的本体描述语言,如 SHOE(Simple HTML Ontology Language)、OIL(Ontology Inference Language)、DAML(DARPA Agent Markup Language)以及 DAML+OIL 等。RDF 也是一种简单的本体描述语言,但其描述能力较弱,需要扩展。OWL 是 W3C 推荐的本体描述语言,其实现较多地参考了 DAML+OIL 的设计思想和经验。

### 5. 逻辑层

逻辑层用来产生规则,主要提供公理和推理规则,为智能推理提供基础。

近年来,随着研究的不断深入,描述逻辑(Description Logic,DL)作为一种较为成熟的知识表示方法引入,对于 OWL 规范的制定起到了一定程度的指导作用。最近,研究人员已经开始尝试在 OWL 加入规则形成 OWL 的规则语言 ORL(OWL Rules Language),以更好地实现自动推理。

### 6. 证明层

证明层执行逻辑层产生的规则,主要提供认证机制,并结合信任层的应用机制评判是否能够信赖给定的证明。

证明层使用逻辑层定义的推理规则进行逻辑推理,得出某种结论。对于语义网的用户而言,这一推理过程应该是建立在可靠的数据基础上,应该是公开的,而且推理得到的结论也应该是可验证的。

### 7. 信任层

信任层主要提供信任机制,以保证用户代理(agent)在 Web 上进行个性化服务和交互更安全可靠。

在语义网内进行推理并最终得出的结论应该是可以信任的,这需要满足的条件如下:

- (1) 可以信任所见的数据,即上下文;
- (2) 可以信任所做的推理过程。

满足上述两点,才可以信任最终得到的推理结果。使用语义网的 RDF 模型,任何人都可以对任何资源进行描述,不同立场的人对相同的资源可能会做出完全相反的描述。信任层负责为应用程序提供一种机制,以决定是否信任给出的论证。信任层的建立,使智能代理在网络上实现个性化服务以及彼此间的自动交互具备可靠性和安全性。

## 12.1.3 元数据

元数据是描述数据的数据,是对万维网信息的一种描述方式,是机器可理解的信息。

元数据由一系列属性或元素组成,以实现查询、阅读、交换和共享。例如图书馆元数据——图书馆目录,包括一系列描述书籍和书面的数据,如作者、出版日期、出版社和书名等元素。

元数据与其所描述的资源之间的关联方式主要包括:



- (1) 元素包含在独立于该资源的记录中,如图书馆目录;
- (2) 数据嵌在资源本身。

Internet 中元数据的概念非常流行,其重要作用体现在:

- (1) 组织和管理网络信息,挖掘信息资源,通过元数据可以在万维网上准确地识别、定位和访问信息。
- (2) 查询所需信息。
- (3) 组织和维护一个机构对数据的投资。
- (4) 建立数据目录和数据交换中心。通过数据目录和数据交换中心等提供的元数据,用户可以共享信息,维护及优化数据等。
- (5) 提供数据转换的信息。用户在获取信息的同时可以得到元数据,通过元数据可理解信息和自身信息集成在一起,进行科学分析和决策。

元数据的编写是有标准的,通常不同领域根据不同的需求制定一种或多种标准。标准的制定可实现数据的交换和共享。一些重要的元数据标准包括 MARC(Machine Readable Cataloging,机器可读编目)和 Dublin Core 等。

### 1. Dublin Core

美国在线计算机图书中心(Online Computer Library Center,OCLC)从用户的角度出发,创建了一种新的网络资源描述标准或格式,都柏林核(Dublin Core,DC)元数据标准应运而生。

当前,DC 元数据集包括 15 个核心元素,分别是:

- TITLE 对象的名称,由创建者或出版商给出。
- SUBJECT 对象所涉及的主题,包括资源或对象的关键字。
- DESCRIPTION 资源内容的描述。
- SOURCE 对象的来源。
- LANGUAGE 文字内容采用的语言。
- RELATION 和其他对象的关系。
- COVERAGE 对象的空间位置和时间持续性特征。
- CREATOR 资源内容的责任人。
- PUBLISHER 能获取对象的责任代理。
- CONTRIBUTOR 主要负责对象文字内容的人。
- RIGHTS 资源权限管理的声明。
- DATE 发布日期。
- TYPE 对象的类型。
- FORMAT 对象的数据格式。
- IDENTIFIER 唯一标识对象的字符串或数字,如 URL 或 URI。

### 2. HL7

HL7(Health Level 7)是由美国国家标准局授权的标准开发机构 HL7 研发的一个专门用于医疗卫生机构及医用仪器、设备数据信息传输的标准。

HL7 适用于医院内部不同医疗信息系统之间交换病例资料、临床检验结果和财务信息,便于医院内部信息的交换和管理。同时,HL7 也适用于医院与医院、医院与保险公司、



医院与上级主管部门之间大量信息的交换需要。

HL7 可应用于多种操作系统和硬件环境,也可以进行多个应用系统之间文件和数据的交换,所有不同平台的医院信息管理系统通过 HL7 都可以顺利交互。采用 HL7 作为标准的 HIS 和医用仪器、设备可以实现无缝连接和医学数据信息的无障碍交换。

HL7 的应用不仅使医院内部不同系统间的交互大大简化,更便于各医院以及医院与其他机构之间的联系。

### 3. IMS

IMS 是一个全球性的学习组织,以发展及推广开放性规范(open specification)为主要任务,主要发展和推广有关教育的开放规范,以促进在线分布式的学习活动。IMS 全球学习联盟的两大目标是其一达成分布式学习环境下应用系统或服务的互操作性,定义、发展所需的技术规范;其二协助其他单位将 IMS 规范纳入产品或服务中。

由于 IMS 并非开发性组织,所制定的规范需要由正式的标准制定机构(如 IEEE 等)进行公开、公正的讨论和审核,投票通过后才能成为正式的标准。目前,IMS 开发完成的规范分别是 IMS 学习资源元数据说明(IMS Learning Resource Metadata Specification)、IMS 企业说明(IMS Enterprise Specification)、IMS 学习者信息包装说明(IMS Learner Information Package Specification)和 IMS 问题与测试互操作说明(IMS Question&Test Interoperability Specification)。

实现元数据的技术手段是 XML 和 RDF。XML 从数据和文档的底层实现格式化,保证从处理到交换的一致性,有利于在网络环境下采用通用的搜索引擎等工具,为实现广义数字图书馆(虚拟数字图书馆)提供可能。

由于不同领域甚至同一领域存在多个元数据标准,当在不同元数据标准描述的资源体系之间检索时,则存在元数据的互操作性问题。利用特定的转换程序对不同的元数据标准进行转换,称为元数据映射(Metadata Mapping/Crosswalking)。目前出现了大量的转换程序,实现各种元数据标准的转换。例如 DC 与 USMARC、DC 与 EAD(Encoded Archival Description,编码档案描述)、DC 与 GILS(Government Information Locator Service,政府信息定位服务)、GILS 与 MARC TEI、Header 与 MARC、FGDC(Federal Geographic Data Committee)与 MARC 等。也可以利用一种中间格式对多种元数据进行转换。相比之下,格式映射转换准确且效率较高。

元数据有四种类型,即内容元数据、管理元数据、负载信息元数据和参考信息元数据,它们从不同的维度、不同的层次描述电子文档或资源。其中:

- 内容元数据 描述对象内容的信息。
- 管理元数据 描述与电子文档相关的信息。
- 负载信息元数据 提供电子文档的物理属性。
- 参考信息元数据 源自电子文档中的超链接。在此“链接”的概念扩展到更一般的概念,用来表示任何万维网信息、文档和资源的参考链接。

#### 12.1.4 核心技术

语义网的体系结构中,XML 层、RDF 层以及本体层是最核心的,它们是语义网知识表



示的基础,为上层的推理、验证等奠定了基础,也是目前发展较为成熟的三种技术,下面将分别简要介绍。

## 1. XML

传统的 Internet 以 HTML 格式存储和组织分布式的文档,这带来的主要问题是:

- 任何人只要发现 HTML 不足以满足其需求时,就简单地在文档中增加标签,结果导致大量、非标准的 HTML 出现。
- HTML 标签主要是面向显示的,并不包含语义,因此很难让机器抽取内容以及自动地处理文档。

为了解决上述问题,W3C 开发了 XML 标准,并确定 XML 为语义网底层的数据交换格式。XML 通过制定标准容许用户自行定义标签,并通过文档类型定义(Data Type Definition,DTD)或 XML Schema 约束这些标签的内部结构,并解决了不同应用之间命名冲突的问题。XML 成功地实现了文档的内容与表示的分离,成为应用程序之间交换数据的最佳选择。

XML 的可扩展性、自我描述性及良好的结构定义,为语义网提供了完美的底层数据交换格式,并通过 XML Schema 规定交换数据的数据结构。然而 XML 并不能对所使用的标签提供语义解释,对机器语义理解没有太大帮助。因此,基于 XML 构建了 RDF 标准,实现对信息资源的语义描述。

## 2. 资源描述框架语言

Web 数据是计算机可读的,但不是计算机可理解的,因此 Web 数据难以实现计算机自动处理。解决这一难题的途径是采用元数据索引 Web 信息,然后使用资源描述框架(Resource Description Framework,RDF)描述元数据与元数据之间的关系。RDF 是处理元数据的基础,为在应用程序之间交换机器可理解的 Web 数据提供了可互操作性。RDF 的应用广泛,如采用 RDF 的智能主题可提高机构之间知识共享和交换的能力。

RDF 定义一个简单的数据模型,通过性质(property)和值(value)描述资源以及资源与资源之间的关系。如果将 RDF 的性质看做是资源的属性,则 RDF 也可以看作传统的<属性,值>模型。此外,RDF 还可以描述资源与资源之间的关系,因此 RDF 类似于一个实体关系图。

RDF 的表示方法有三种,即图示法、模型和三元组。在 RDF 模型中,资源以资源标识符表示,资源标识符由一个唯一资源标识符和一个可选的锚(anchor)ID 组成。

RDF 提供了一个开放的表达 Web 资源的元数据描述模型,由一系列的陈述即主体谓词客体三元组组成。可以表达 Web 上可标识的任何资源,如标题、作者、Web 文档的版权和注册信息、语言、格式和条目等。RDF Schema 是一个描述 RDF 资源的属性和类的词汇表,提供了关于这些属性和类的层次结构的语义,从某种程度上拓展了这种资源描述的能力,可以看成是轻量级的 Web 本体语言。

下面介绍 RDF 和 XML 的主要区别。

### (1) XML 不包含语义,RDF 包含语义。

判断是否包含语义,需要知道语义的含义,机器可理解的语义是指由符号表示的对象与对象之间的关系;而语法则是指符号与符号之间的关系。

之所以说 XML&XML Schema 不包含语义,是指它们并不能使机器理解对象与对象之



间的含义；而 RDF&RDF Schema 之所以包含语义，是指它们能表达标签所对应的对象之间的含义，而且包含了谓词逻辑并支持推理，如图 12.2 所示。

```
<rdf:Description rdf:about = "http://www.famouswriters.org/twain/mark">
<s:hasName> Mark Twain</s:hasName>
<s:hasWritten rdf:resource = "http://www.books.org/ISBN0001047582">
</rdf:Description>
<rdf:Description rdf:about = "http://www.books.org/ ISBN0001047582">
<s:title> The Adventures of Tom Sawyer</s:title>
<rdf:type rdf:resource = "http://www.description.org/schema# Book">
</rdf:Description>
```

图 12.2 RDF 实例

图 12.2 所示的例子表达的是 Mark Twain 写了 *The Adventures of Tom Sawyer* 一书，即在二者之间建立了 hasWritten(已写)的关系，这种关系也可以在 RDFS 中进行描述，这种关系能在 RDFS 与其他词汇之间建立联系(如父子关系、定义域、值域等)。

上述例子以 XML 表示如图 12.3 所示。

```
<description>
<hasName> Mark Twain</hasName>
<hasWritten>
  <description>
    <book>
      <title> The Adventures of Tom Sawyer</title>
    </book>
  </description>
</hasWritten>
</description>
```

图 12.3 XML 实例

通过上述结构，人们可以明显地看出其中的关系，但机器仍然无法理解 Mark Twain 和 The Adventures of Tom Sawyer 是什么关系，而只知道它们分别是树结构中的第二级结点和第五级结点。

因此，RDF 用来描述资源(或对象)，并建立它们之间的语义关系。

(2) XML 的结构是树，RDF 的结构是图。

RDF 的三元组在文件中出现的顺序是随意的，三元组有多个谓词和客体时，其在陈述中被定义的顺序也是随意的；而 XML 中一个结点出现的顺序却不能更换。

(3) XML Schema 定义的是 XML 的词汇表，而 RDF Schema 定义的是词汇类型。

XML Schema 定义了 XML 中的词汇及其在树状结构中的位置关系，而 RDF 的词汇集太大了，大到 RDF Schema 无法描述，因此 RDF Schema 定义的是 RDF 中的词汇类型，并且定义了概念间的语义，如概念的父子关系、定义域及值域等。

然而，同其他知识表示语言相比 RDF Schema 显得过于简单，语义表达能力不够，需要更上层对其语义解释能力的进一步扩展。

### 3. 本体

本体是支持知识共享和重用的形式化结构，将信息的结构和内容分离，实现对信息进行



完全形式化的描述,为信息提供一个统一的共同表达的语义结构。

本体的主要作用是:

- 为人类和应用系统提供一个对于主题的共同理解。
- 为不同来源的信息合成提供一个共同的相关领域的理解。
- 为不同的应用程序之间共享信息和知识,描述应用程序的领域,定义术语及其关系。

对于以概念的共享和理解为核心的语义网,本体提供了语义知识的明确化表示方法,因此本体在语义网中处于核心支配地位,后面将详细介绍本体。

### 12.1.5 开发工具 Jena

Jena 是一套开发语义网应用的 Java API,包括对 RDF、RDFS 和 OWL 描述的本体模型的解析、创建和串行化等,SPARQL 语句的解析,转化为 SQL 以及基于规则的推理引擎。

Jena 提供了读取、创建和输出模型的 Java API。其主要的数据结构是图,但是用户操作主要还是在模型上进行。基本方法是通过 ModelFactory 建模,然后通过模型创建资源,再通过资源添加属性,逐步构成一个图。

通过 model.listStatement() 方法可以得到所有 Statement 的游标,可以遍历模型中所有的三元组。但在取出三元组各部分时需注意,对象可以是字符也可以是资源,需要测试。

RDF 图中的一个结点或本体中的一个资源,在 RDF 中以 `<rdf:Description rdf:about = "${uri}>` 开始,uri 指出了资源的 URI。如果下面有匿名资源,或者图中有空白结点则用 `<${prediction} rdf:nodeid = "${anonymousenodeid}">`,另外再使用 `rdf:Description` 描述该空结点,即 `<rdf:Description rdf:nodeid = "${anonymousenodeid}">`。当然,人工编写时通过嵌套可以不用创建匿名资源。

### 12.1.6 Web 3.0

Internet 经历了翻天覆地的重大变革。伴随着从 Web 1.0 向 Web 2.0 的过渡,Web 3.0 已开始逐渐步入人们的视野。Web 2.0 虽然只是互联网发展阶段的过渡产物,但正是由于 Web 2.0,让人们可以更多地参与到 Internet,特别是内容上的创造。在这一点上 Web 2.0 具有革命性的意义。正是因为更多的人参与到了有价值的创造活动,那么要求互联网价值的重新分配将是一种趋势,因而必然催生新一代 Internet——Web 3.0。

Web 3.0 开发者们的目标是建造一个能针对简单问题给出合理、完全答复的系统。Web 3.0 标准的核心是:

(1) 继承 Web 2.0 的所有特性。如以用户为中心,用户创造内容,广泛采用 Ajax 技术,广泛采用 RSS 内容聚合,表现为 BLOG 大行其道,Internet 上涌现大量的个人原创日志等。

(2) 帮助用户实现其劳动价值。目前的 Web 2.0 几乎都是用户免费劳动,免费生产内容娱人娱己。用户很难通过 Web 2.0 网站把自己辛辛苦苦生产的内容兑换成真实货币。Web 3.0 的首要任务是让他们不再浪费劳动力,实现劳动价值。

(3) 网站无边界,遵守 Web 3.0 标准的网站可以方便地在数据、功能上实现彼此的互通、互动。未来的 Internet 是合作、共赢、资源互补、互促的 Internet。分久必合,有相关利



益的网站会联合起来,趋于一体化。一个强有力的、方便的对外交互的标准是每个 Web 3.0 网站都必须实现的。

(4) 具备更清晰、可行的盈利模式。现在的 Web 2.0 网站大部分没有清晰可行的盈利模式,这是商业网站的致命弱点。有些 Web 2.0 网站有一些广告收入,但只是杯水车薪,一开始投资太大、烧钱太多、人不敷出,注定要成为饿死的骆驼。

(5) 不仅限于 Internet 应用,这是 Web 3.0 标准的外延,可以应用到其他非互联网行业。

实现 Web 3.0 的三个前提是:

(1) 博客技术为代表,围绕网民互动及个性体验的互联网应用技术的完善和发展。

(2) 虚拟货币的普及,以及虚拟货币的兑换成为现实。

(3) 大家对网络财富的认同,以及网络财务安全的解决方案。

Web 3.0 与 Web 2.0 一样,不是技术的创新而是观念的创新,进而引领技术的发展和应用。Web 3.0 将催生新的王国,不再以地域进行划分,而是以兴趣、语言、主题、职业、专业进行聚集和管理的王国,可谓“皇帝轮流做,明年到我家”,每个用户都有机会打造出一个新的互联网王国而成为一个国王,也有可能在互联网王国的民主竞选中成为“总统”,到时将拥有来自全球各个角落的网络公民。

过去的 Web 1.0 采用超链接解决了信息孤岛的连接问题,Web 2.0 解决了网络发言权的解放问题,Web 3.0 则是要解决海量信息在细化后的定向搜索与获利机制问题。当 Web 3.0 为用户提供了更好的提升自我的整合能力后,这意味着能够更好地成为一个围绕用户服务的整合中心,这正是我们期待未来的 Web 3.0 受到用户欢迎的原因。

Web 1.0 被 Web 2.0 重新洗牌后,人人都有话语权,但是谁来听,谁来买单才是根本。也许正是因为还不涉及利益分配的原因,Web 2.0 得以迅速发展。同样,因为 Web 2.0 还没有形成良性的商业回报机制,所以一个能解决“利益分配”问题——将主要利益分配给最有贡献的内容提供者的 Web 3.0 便应运而生。

随着 Internet 的日新月异,Web 3.0 将是彻底改变人类生活的互联网形式。Web 3.0 使所有网民不再受到现有资源的限制,具有更加平等地拥有获得财富和声誉的机会。事实上,Web 3.0 已经投入使用,只不过是了解不多,如电子商务和在线游戏,不管是 B2C 还是 C2C 模式,网民利用 Internet 提供的平台进行交易,整个过程中他们通过 Internet 付出了劳动并收获了财富。在线游戏通过积分的方式,角色扮演者通过攻城掠寨、花费大量的时间不断修炼,他们在那里可以获得声誉和财富,而这种财富通过一定的方式可以在现实中兑换,正所谓人生如同一场游戏,Internet 会让人们的生活变得更像游戏。当前的论坛也提供积分,但由于缺乏个性,不会成为未来的主流,最有代表性的博客,却在积分方面做得很少,劳动价值没有得到体现。为此,好的 Blogger 将另起炉灶,以便得到更多,这是在追求一种更加均衡的分配方式。

Web 3.0 究竟能够做些什么? DWS Group 推出其第一个 Web 3.0 的应用智能相册 (Smart Albums),它是一款简单易用的图片管理软件,集相册分类、图片标签和图片搜索等功能为一体,并可以日历模式展现,还可以对图片进行加密保存等。Web 3.0 在医疗领域已有应用,据调查美国的所有医学测试中,近 40% 是因为不知道病人以前的测试结果而进行的。所幸的是,在电子病例领域,现在出现了 WorldVista 的开源标准,这个由 VA 开发的基



于 Vista 的标准向所有人开放,能够形成一个全球性的可互换医疗信息系统。Google 目前已完成了从信息制作、组织、存储、检索、发布、翻译和服务,以及无线服务 Google SMS 的一整条 Web 3.0 产业链的构建。Web 3.0 时代网络连接速度将达到 10Gbps,越来越多的家庭都用上了数据传输速率达 2~3Gbps 的连接,用户可以观看电影片花等多媒体内容,为 eBay、Salesforce.com 等互联网巨头开拓了新的市场。可见,Web 3.0 作为一种新的理念,逐步融入我们的生活。

很多 Web 3.0 的尝试已经开始,但这些尝试聚合起来还需要一个漫长的过程,现在的 Web 3.0 如同一堆碎石,等待被整理为一条畅通的公路。我们今天描述 Web 3.0,就如同当年在 Internet 诞生之前想象 Web 1.0 一样。

无论如何,我们已经奔驰在信息高速公路上,大家需要重新认识信息的本质。现在要做的是按照信息在现实中存在的属性和信息之间的关系结构建立公用信息标准,并按照这个标准搭建公用信息平台,通过不断地完善和升级,最终实现 Internet 的真正价值。

## 12.2 本体

本体是近来信息科学界最热门的词汇之一。在各种信息交互和集成、知识表示与获取的应用中,这一词汇频繁出现,本体到底是什么?

### 12.2.1 哲学本源

本体的概念最初起源于哲学领域,并在很长一段时期都是哲学研究的一个分支。古希腊哲学家亚里士多德(Aristotle)定义本体为“对世界客观存在物的系统描述,即存在论”,即本体是客观存在的一个系统的解释或说明,所关心的是客观现实的抽象本质。为研究客观世界的存在问题,亚里士多德、莱布尼茨、康德、皮尔斯和怀特海德等哲学家广泛地讨论了如何运用本体对现实世界进行分类、如何描述其中的物理实体、如何定义客观世界的抽象以及空间与时间的关系等问题。虽然,历史上对本体的思考主要是从哲学和逻辑学的角度,但前人的研究成果蕴涵了很多如何组织现实世界知识的方法,这为本体被信息科学所借鉴奠定了基础。逻辑在信息科学中占有重要地位,但人们认识到逻辑没有描述具体现实世界的能力,逻辑中的存在量词符号仅仅能声明某物存在,但逻辑本身却没有词汇来描述到底存在的是什么,本体由此被引入信息科学中,以弥补逻辑表达能力的不足。本体包含了观察与推理两个范畴。观察提供现实世界的知识,描述知识的组织形式;推理通过虚拟框架澄清观察的意义,描述知识的语义。

20 世纪 90 年代,信息科学的发展面临着种种新难题,诸如知识表示、知识共享和复用等。特别地,由于 Internet 的飞速发展,如何组织、管理和维护海量信息并为用户提供有效的服务成为一项重要而迫切的研究课题。本体作为一种能在语义和知识层次上描述信息系统的概念模型的建模工具,引起了国内外众多研究者的关注,并在计算机领域得到广泛应用,如知识工程、数字图书馆、软件复用、信息检索、Web 异构信息的处理和语义网等。



### 12.2.2 定义

本体这一哲学范畴,被人工智能赋予了新的定义,并引入到信息科学中。然而信息科学界对本体的理解也是逐步发展并走向成熟的。1991年 Neches 等人最早给出的本体在信息科学中的定义是构成相关领域词汇的基本术语和关系,以及利用这些术语和关系构成规定这些词汇外延的规则。后来随着研究的深入,在信息系统、知识系统等领域对本体给出了不同的定义,如1993年 Gruber 定义本体为“概念模型的明确的规范说明”;1997年 Borst 进一步完善为“共享概念模型的形式化规范说明”。Studer 等人对上述定义进行了深入研究,认为本体是共享概念模型的明确的形式化规范说明。

Studer 等人的本体定义包含四层含义:概念模型(conceptualization)、明确(explicit)、形式化(formal)和共享(share)。其中,概念模型是指通过抽象客观世界中一些现象的相关概念得到的模型,其表示的含义独立于具体的环境状态;明确是指所使用的概念及使用这些概念的约束都具有明确的定义;形式化是指本体是计算机可读的,也是计算机可处理的;共享是指本体中体现的是共同认可的知识,反映的是相关领域中公认的概念集,针对的是团体而非个体。本体的目标是捕获相关领域的知识,提供对该领域知识的共同理解,确定该领域内共同认可的词汇,并从不同层次的形式化模式上给出这些词汇(术语)和词汇之间相互关系的明确定义。尽管定义有很多不同的方式,但就内涵而言,不同研究者对于本体的认识是统一的,都将其看作领域(领域的范围可以是特定应用,也可以是更广的范围)内部不同主体(人、机器、软件系统等)之间进行交流(对话、互操作、共享等)的一种语义基础,即由本体提供一种共识,而且提供的这种共识更主要的是为机器服务,机器并不能像人类一样理解自然语言表达的语义,目前的计算机也只能把文本看成字符串进行处理。

到底什么是本体?学术界对此并没有达成共识,引用较多的是 Gruber 的定义,即本体是一个共享的概念化规范,而概念化是指某个领域中的概念及其相互关系,是我们希望描述的世界的一个抽象的、简化的视图。

本体与通常所谓的词典的区别在于:

- (1) 词典是人读的,本体必须方便机器阅读。
- (2) 词典注重概念本身的描述,本体既注重概念本身的描述,又注重概念间之间关系的表示。
- (3) 词典通常以自然语言描述,本体可以用其他符号语言描述。

经过多年的努力,研究人员已经构建了一些有影响力的本体。

### 12.2.3 建模

本体是一种组织知识的艺术。为研究如何利用本体组织知识,Perez 等人采用了分类法,并归纳出五个基本建模元语:类(class)或概念(concept)、关系(relation)、函数(function)、公理(axiom)和实例(instance)。类或概念表示对象的集合;关系表示领域中概念之间的交互作用;函数是一类特殊的关系,该关系的前  $n-1$  个元素可以唯一决定第  $n$  个元素;公理代表永真断言;实例代表元素,就语义而言表示的就是对象。关系在本体中非



常重要,从语义的角度,基本的关系包括四种: part of、kind of、instance of 和 attribute of。part of 表示概念之间部分与整体的关系; kind of 表示概念之间的继承关系,类似于面向对象中父子类之间的关系; instance-of 表示概念的实例与概念之间的关系,类似于面向对象中对象和类之间的关系; attribute-of 表示某个概念是另一个概念的属性。实际建模中,概念之间的关系不限于上述四种基本关系,可以根据领域的具体情况定义相应的关系。本体正是通过这些建模元语组织现实世界的知识。

#### 12.2.4 分类

目前,广泛使用的本体包括 WordNet、FrameNet、GUM 和 SENSUS 等。WordNet 是基于心理语言规则的英文词典,以在特定的上下文环境中可互换的同义词的集合为单位组织信息; FrameNet 英文词典采用称为 Frame Semantics 的描述框架,提供强大的语义分析能力,目前发展为 FrameNet II; GUM 面向自然语言处理,支持多语种处理,包括基本概念及独立于各种具体语言的概念组织方式; SENSUS 面向自然语言处理,为机器翻译提供概念结构,包括 7 万多个概念。

对于本体的分类有着不同的标准。常用的本体划分准则是详细程度和领域依赖程度。详细程度是为了描述或刻画建模对象的程度,高的称作参考本体(reference ontology),低的称作共享本体(share ontology)。根据依赖程度可以划分为四类,即:

(1) 顶级(top-level)本体描述的是最普遍的概念和概念之间的关系,如空间、时间、事件、行为等,与具体应用无关,其他本体均为其特例;

(2) 领域本体(domain ontology)描述的是特定领域中的概念和概念之间的关系;

(3) 任务本体(task ontology)描述的是特定任务或行为中的概念和概念之间的关系;

(4) 应用本体(application ontology)描述的是依赖于特定领域和任务的概念和概念之间的关系。

#### 12.2.5 构建方法

如何构建本体? Gruber 提出了五条准则,即:

(1) 清晰性(clarity) 本体必须有效地说明所定义术语的含义,定义应该是客观的,与背景独立的,当定义可以用逻辑公理表达时,应该是形式化的,定义应该尽可能地完整,所有定义应该用自然语言说明。

(2) 一致性(coherence) 本体应该是一致的,换言之应该支持与其定义相一致的推理,它所定义的公理以及用自然语言进行说明的文档都应该具有一致性。

(3) 可扩展性(extendibility) 本体应该为可预料到的任务提供概念基础,应该支持在已有概念的基础上定义新的术语,以满足特殊需求,而无须修改已有的概念定义。

(4) 编码偏好程度最小(minimal encoding bias) 概念的描述不应该依赖于某一种特殊的符号表示方法,因为实际系统可能采用不同的知识表示方法。

(5) 约定最小(minimal ontological commitment) 本体约定应该最小,只要能够满足特定的知识共享需求即可,这可以通过定义约束最弱的公理以及只定义通信所需的词汇来



保证。

对于本体构建方法,大多数研究者都倾向于采用一种近似软件工程的方法。本体构建一般分为若干步骤,是一个不断迭代、逐步精炼的过程,主要步骤包括:

- (1) 确定本体的目的和使用范围。
- (2) 本体捕获:即确定关键的概念和关系,给出精确定义,并确定其他相关的术语。
- (3) 本体编码:选择合适的语言表达概念和术语。
- (4) 已有本体的集成:尽可能重用和修改已有本体。
- (5) 评估:根据需求描述、能力询问(competency question)等对本体以及软件环境、相关文档进行评价。

由于到目前为止本体仍处于相对不成熟的阶段,每个工程都有自己独立的方法。最常用的本体构建方法是骨架法、IDEF-5法和循环获取三种,已得到业界的普遍认可,下面将分别介绍。

### 1. 骨架法

Mike Ushold 和 Micheal Gruninger 提出的骨架法(skeletal methodology)在企业本体基础上,是相关商业企业间术语和定义的集合。该方法只提供开发本体的指导方针。在构建过程中虽没有提出特有的评价方法,但是认为评价方法应该是其中的一个环节,具体步骤如下:

#### 1) 确定目的和范围(identify purpose and scope)

在此阶段需要确定建立本体的目的、本体应用的范围以及用户群等。

#### 2) 建立本体(building the ontology)

这一阶段包括本体获取、本体编码和现有本体的集成。

#### 3) 评价(evaluation)

没有提出自己的评价方法,只是认为评价应该是整个方法论的一个环节。

#### 4) 文档化(documentation)

包括本体定义的主要概念、元本体等。目前很多知识库和本体缺少文档也是一种知识共享的障碍,某些编辑器可以自动生成这些文档。

### 2. IDEF-5 方法

IDEF(ICAM Definition Method)的概念是在结构化分析方法的基础上发展而来的,1981年美国空军公布的 ICAM(Integrated Computer Aided Manufacturing)工程首次使用了名为 IDEF 的方法。到目前为止,已经发展成为一个系列。IDEF 5 通过两种语言(即图表语言和细化说明语言)获取某个领域的本体,提供流程图和对象状态转移网图这两种图表获取、管理和显示过程。

IDEF-5 提出的本体构建方法包括五个活动,分别是:

#### 1) 组织和范围(organizing and scoping)

确定本体建设项目的目标、观点和语境,并为组员分配角色。

#### 2) 数据收集(data collection)

收集本体建设需要的原始数据。

#### 3) 数据分析(data analysis)

分析数据,为抽取本体做准备。

#### 4) 初始化的本体建立(initial ontology development)

从收集的数据中建立一个初步的本体。

#### 5) 本体的精炼与确认(ontology refinement and validation)

完成本体构建过程。

### 3. 循环获取

Alexander Maedche 等人提出的循环获取(Cyclic Acquisition Process)方法是一种环状结构,如图 12.4 所示。




图 12.4 循环获取法

具体过程如下:

#### 1) 环形的起点是一个通用的核心本体的选择。

任何大型的通用本体(如 Cyc、Dahlgren 的本体)、词汇语义网(如 WordNet、EuroWordNet、HowNet)或领域相关的本体都可以作为这一过程的开始。选定基础本体后,用户必须确定用于抽取领域相关实体的文本。

#### 2) 从选择的文本中获取领域相关的概念,并建立概念之间的分类关系。

#### 3) 除去领域无关的概念,只留下和领域相关的。这时,建立了目标本体的概念结构。

#### 4) 从基础本体中继承一些关系,其他的关系需要通过学习的方法从文本中抽取。

#### 5) 对获得的领域相关的本体进行评价,还可以重复上述过程。

构建本体需要一种表示语言作为基本的形式化工具。原则上,本体能够用各种各样的语言实现,如非形式化的、半形式化的或形式化的,并无强制性的规范。目前,有两种逻辑常用作本体的形式化工具,其一谓词演算及其变种;其二是框架逻辑。其中,谓词演算及其变种较为常见。如 M. R. Genesereth 和 R. E. Fikes 提出的 KIF(Knowledge Interchange Format)是一种基于扩展的谓词演算的形式语言,包含类、子类、属性、值、关系和公理等原语; Ontolingua 的本体就是使用框架本体,其语法基于 LISP; CYCL 是 CYC 的知识表示语言,类似于一阶谓词演算; XOL(XML Based Ontology Exchange Language)是一种本体交换语言,提供本体定义格式的交换,基于 XML 语法; OIL(Ontology Inference Language)是基于框架的表示语言,目前还在不断完善中。



### 12.2.6 描述语言

下面以 OWL(Web Ontology Language,网络本体语言)为例介绍本体描述语言的功能特性。

OWL 是 W3C 推荐的语义互联网中本体描述语言的标准。W3C 总结了之前的 DAML+OIL、RDF 和 RDFS 等几种语言的开发经验,在 2004 年 2 月正式推出 OWL。OWL 是语义网发展过程的一个重要里程碑,经过广泛的讨论并得到比较一致的认可。OWL 既保持了对 DAML-ONT/OIL/RDFS 的兼容性,又保证了更强大的语义表达能力,还保证了描述逻辑的可判定推理等。W3C 提出的本体语言栈如图 12.5 所示。

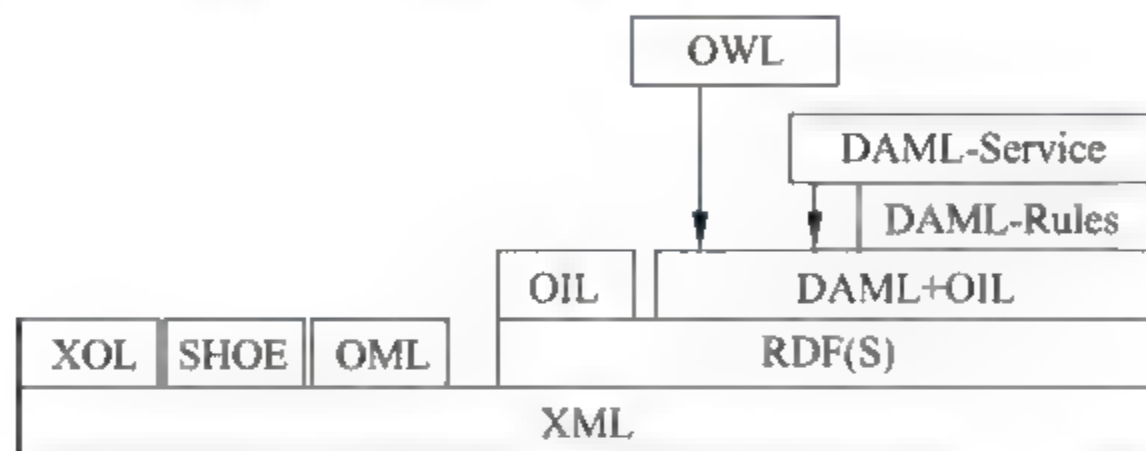


图 12.5 W3C 提出的本体语言栈

RDFS 提出类的概念,定义类和性质,可以描述其他类和性质,然而其表达能力非常有限。RDFS 局限于子类分层和属性分层,以及属性的定义域和值域限定,难以提供推理方面的支持。W3C 确定的语义网用例所需的表达能力要比 RDF 和 RDFS 强得多,OWL 由美国和欧洲等研究机构联合提出的 DAML+OIL 语言发展而来,具有良好定义的语法,高效率的推理支持,以及充分灵活的语义表达能力,从根本上解决了 RDF 和 RDFS 表达语义的局限性,成为 W3C 推荐的本体描述语言的标准。

OWL 和 RDF/RDFS 中一些建模原语的关系如图 12.6 所示。

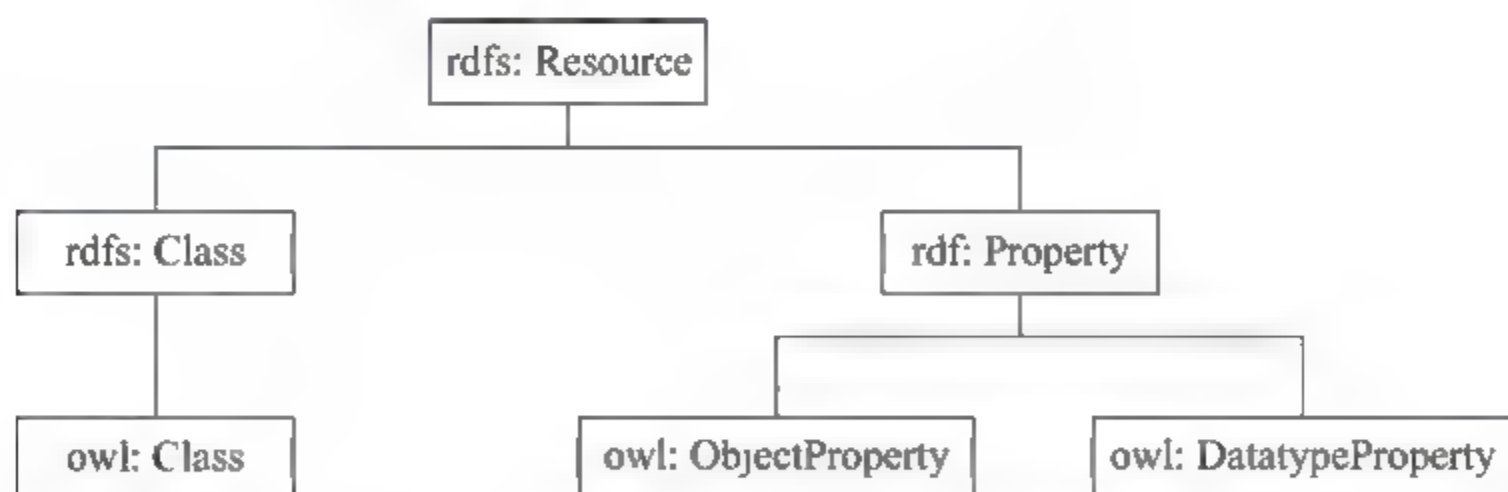


图 12.6 OWL 和 RDF/RDFS 建模原语的关系

RDFS 的局限性如下:

(1) 属性的局部辖域。rdfs:range 为一个属性(例如吃)定义的值域是相对于所有类的,无法定义只适用于某些类的值域限制(例如无法定义牛只吃植物,而其他动物还可以吃肉)。

(2) 类不相交性。有时需要表示类的不相交性,例如男性和女性不相交。但 RDFS 只能规定类之间的子类关系,如女性是人类的子类。

(3) 类的布尔组合。有时希望通过对已有类进行并、交或补等操作,组合产生新的类,例如定义人类为男性和女性的不相交的并,RDFS 则不容许这样的定义。

(4) 基数约束。有时需要对一个属性不同取值的个数加以约束。如一个人恰好有一个父亲和母亲,一门课程至少有一个授课者讲授,RDFS 同样不能表达这样的约束。

(5) 属性的特殊性质。有时候需要规定属性具有传递性(如大于),唯一性(如母亲)或定义属性的逆属性(如吃和被吃)。

OWL 针对 RDFS 的局限进行了以下扩展:

(1) OWL 中使用 owl:import 可以导入其他本体,该语句具有传递性。

(2) 类元素: owl:Class 进行类定义; owl:disjointWith 表示类的不相交; owl:equivalentClass 表示类相等。此外,还包含两个预定义类 owl:Thing 是所有类的父类; owl:Nothing 是空类,是所有类的子类。

(3) 属性元素:有两种属性,即 owl:ObjectProperty 和 owl:DatatypeProperty。前者将对象关联起来,常表示为动作;后者将对象和属性值关联起来,owl 没有预定义的数据类型,使用 XMLS 的数据类型。可以定义属性的逆属性和等价属性,分别使用 owl:inverseOf 和 owl:equivalentProperty。

(4) 属性约束:通过 owl:Restriction、owl:allValuesFrom/owl:hasValue、owl:someValuesFrom 规定 owl:onProperty 指定属性。分别表示该 property 的取值必须“全部或至少有一个”来自某范围。owl:allValuesFrom 和 owl:hasValue 的区别在于前者指定的是类或一个数据范围,而后者指定的是一个个体或一个值。

(5) 类的交、并、补: owl:intersectionOf、owl:unionOf、owl:complementOf。

(6) 类的枚举: owl:one of。

(7) 类的实例:同 RDF。

(8) 基数约束: owl:Restriction、owl:minCardinality、owl:maxCardinality。

(9) 特殊性质:传递性 owl:TransitiveProperty; 对称性 owl:SymmetricProperty; 函数性 owl:FunctionalProperty(如规定同一个对象的该属性不可以取同一个值,如年龄、身高等); 逆函数性 owl:InverseFunctionalProperty,即规定不同对象的该属性不可以取相同的值,如身份证号。

OWL 和其他知识表示语言表达能力的比较如表 12.1 所示。

表 12.1 OWL 与其他知识表示语言表达能力的比较

	XML DTD	XML Schema	RDF Schema	OIL	DAML+OIL	OWL
有界列表				✓	✓	✓
基数约束	✓	✓		✓	✓	✓
类表达式			✓	✓	✓	✓
数据类型		✓	✓	✓	✓	✓
已定义的类				✓	✓	✓
枚举	✓	✓		✓	✓	✓
等价				✓	✓	✓
可扩展性			✓	✓	✓	✓



续表

	XML DTD	XML Schema	RDF Schema	OIL	DAML+OIL	OWL
形式化语义			✓	✓	✓	✓
继承			✓	✓	✓	✓
推理				✓	✓	✓
本地化约束				✓	✓	✓
条件约束					✓	✓
实例化			✓		✓	✓

### 12.2.7 实例

目前,一些具有代表性的本体包括 WordNet、CYC、Sensus 和 HowNet 等。其中:

WordNet 是一个基于语言心理学原理的英语词汇数据库,可用作词典、推理词典和分类词汇数据库。

CYC 是世界上最大、最完善的常识知识库。

Sensus 是一个主要用于机器翻译的本体实例。

HowNet(知网)是目前国内一个不可多得的共享本体。下面主要从基本概念、知识结构和概念关系三方面介绍 HowNet。

1999 年初,中国中文信息学会常务理事董振东在 Internet 上公布了自己的研究成果 HowNet。它是描述概念与概念之间的关系,以及概念的属性与属性之间的关系的知识库,支持中、英文两种语言,有着自己独特的知识表示方法。近些年,HowNet 的出现使人们对汉语语义的研究又盛行起来。

HowNet 把客观世界看做是由很多概念构成的。概念与概念之间有各种各样的关系,这些关系相互交织构成了一个网。这种以网状结构组织概念的方式,使得简单的概念描述可以表达丰富的概念关系,这是 HowNet 区别于其他语义词典的本质特征。

HowNet 是一个常识知识库,用 KDML(Knowledge Dictionary Markup Language)作为其知识表示的语言,然而由于这种描述知识的方法并没有得到广大应用的支持,且对于 HowNet 作为知识库本身,没能够提供一套完好的添加知识实例的方法。因此,以 HowNet 原始系统作为知识库,距离实际的应用还有一段差距,但作为一种珍贵的语言学资源,HowNet 可以发挥其积极作用。所以我们更愿意把 HowNet 理解为一种定义完好的半结构化语义词典进行利用。

HowNet 有几个重要的概念,如概念、属性、义原和动态角色等。其中,预定义了一千多个义原,用来描述概念的静态特征,而动态角色用来激活概念的静态特征,使概念与概念之间以及概念间的属性之间动态联系。其中:

#### 1. 概念

即词语的意义,而词语是概念的形式。同一个概念可能有不同的词语形式,包括不同语言的。如“医生”和 doctor 表达的是同一个概念。没有意义的字也就没有概念,如“葡”。HowNet 中有 22574 个概念,由中、英两种语言的各 70000 多词语表示,总记录数是 150100。虽然没有一个记录是重复的,但两种语言对应的词语是重复的。HowNet 中概念

用一个英语和汉语词语的组合来确定概念的唯一性。

## 2. 属性

即概念的特征。一个实体所具有的属性是多元的,正是属性的多元化体现了关系的多元化。例如“纸”有颜色这一属性,正是这一属性造成它可能与“笔”、“写”和“画”发生关系。在日常生活中人们还会用“纸”来点火,这是由于它另外一个属性“易燃性”造成的,这时颜色的属性变得无关了。

## 3. 义原

又称为义素,是意义的最小单位。HowNet 中所有概念定义的基本成分是义原。义原分为五类,每个类别的义原形成一个树状的层次结构。HowNet 中,概念的主要特征即第一个属性,由位于主要特征文件中的义原描述,如实体表、事件表、属性值表和属性表等文件中的义原。因此,HowNet 中概念的上下位关系,由其第一义原的层次结构体现,而概念的其他属性可由任意义原描述,包括次要特征义原、数量表和数量值表等。

## 4. 动态角色

用于描述概念的动态特征,如图 12.7 中所示医生是医治的施事者,病人是医治的受事者。动态角色常用于标注复杂的概念,格式为“动态角色—义原”,其中的动态角色可以为 Agent/(施事者)、Patient/(受事者)、Instrument/(工具)、LocationFin/(终处所)等。

不同于 WordNet、EuroWordNet 等国外盛行已久的语义词典,HowNet 除了能很好地支持中文,另一个特点是面向计算机的网状知识系统,这是它与其他树状词汇词典的本质不同。HowNet 的网状知识体系如图 12.7 所示。

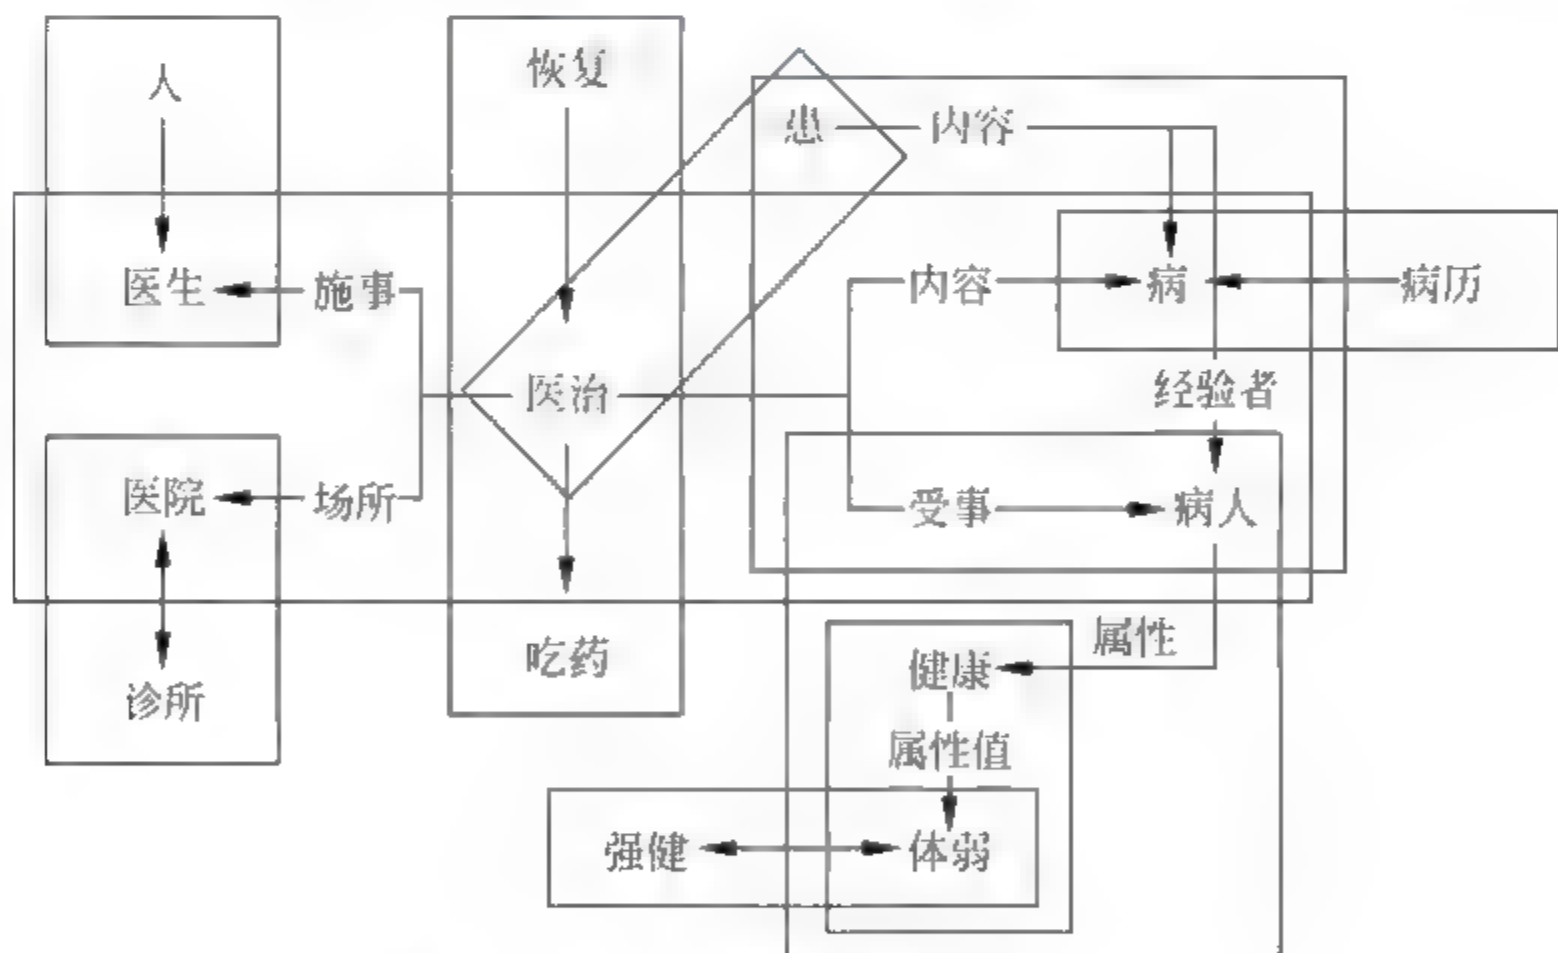


图 12.7 HowNet 的网状知识体系结构

图 12.7 所示的网状知识结构在 KDML 中的表达方式如图 12.8 所示。

其中,每个概念的定义项都由义原和动态角色描述。如 content、LocationFin、domain 等为动态角色,而出现在定义项中由双语标注的是义原。HowNet 中,义原通过一个树状的层次结构构成上下位关系,也具有同概念一样的定义格式,如图 12.9 所示。

通过这样的定义方式,使概念的关系图容易被计算机所理解,让计算机通过理解概念的语义作为其提供智能服务的基础。



```

医生:
DEF = {human|人:domain = {medical|医},HostOf = {Occupation|职位},{doctor| 医治:agent = {~}}}
患者:
DEF = {human|人:domain = {medical|医}, {SufferFrom|罹患:experiencer = {~}}, {doctor| 医治:
patient = {~}}}
医院:
DEF = {InstitutePlace|场所:{doctor| 医治: location = {~},content = {disease|疾病}}, domain =
{medical|医}}
病历:
DEF = {document|文书:{record|记录:content = {disease|疾病},LocationFin = {~}}, domain =
{medical|医}}
健康:
DEF = {Health|健康: host = {AnimalHuman|动物}}
多病:
DEF = {unhealthy|不健康}
病:
DEF = {disease|疾病}
药:
DEF = {medicine|药物}

```

图 12.8 HowNet 概念的定义

```

| {HealthValue|健康值}
| ---- {healthy|健康}
| ----- {unhealthy|不健康}

disease|疾病:
DEF = {phenomena|现象: {doctor|医治:content = {~}},
      {SufferFrom|罹患: content = {~}},
      RelateTo = {medicine|药物}{Health|健康}{HealthValue|健康值},
      domain = {medical|医}}
medicine|药物:
DEF = {artifact|人工物:{doctor|医治:instrument = {~}},RelateTo = {disease|疾病},
      domain = {medical|医}{chemistry|化学}}

```

图 12.9 HowNet 义原的层次结构和定义

概念关系是 HowNet 的灵魂,正是因为有了丰富的概念关系,HowNet 才包含了丰富的语义。HowNet 描述概念之间的多种类型关系,有显性的,也有隐性的,还有组合的关系。

显性关系通常通过动态角色体现,例如:

- 部件-整体关系,通过动态角色 PartOf 描述。如火车有部件-整体关系的词语包括餐车、车厢、豪华车厢、客车、车厢、旅客车厢、寝车、卧车、火车头、蒸汽机车和机车。
- 属性-宿主关系,通过动态角色 HostOf 描述。
- 材料-成品关系,通过动态角色 MaterialOf 描述。
- 施事-事件关系,通过动态角色 Agent 描述。
- 受事-事件关系,通过动态角色 Patient 描述。
- 工具-事件关系,通过动态角色 Instrument 描述。

- 场所-事件关系,通过动态角色 Location、LocationIni、LocationFin 等描述。
- 时间-事件关系,通过动态角色 Time、TimeAfter、TimeBefore 等描述。
- 值-属性关系,无须动态角色,直接标注。

HowNet 定义了百余个动态角色与特征表示概念的动态关系。

HowNet 的许多关系是隐含在特征文件和概念词典描述中,通过一些特殊的结构和位置信息体现出来,如概念间的上下位关系通过定义项中第一个义原的层次结构体现出来,而对义关系则通过对义关系中的两两特征对体现出来。

HowNet 的隐性关系包括:

(1) 上下位关系 —— 即概念间的父子关系,如“苹果”是“水果”的下位概念,“水果”是“植物”的下位概念。

(2) 同义关系 —— 即不同的词语形式表达同一种概念。如“西红柿”和“番茄”是同义词,而“西红柿”和“红薯”不是同义词,只是同类词。HowNet 中,通过中、英文词形以及定义项体现同义关系,如表 12.2 所示。

表 12.2 HowNet 概念定义的实例

Id	中文词形	英文词形	定 义
089505	西红柿	tomato	{ part 部件; PartPosition={embryo 胚}, whole={vegetable 蔬菜}, {eat 吃; patient={~}}}
025550	番茄	tomato	{ part 部件; PartPosition={embryo 胚}, whole={vegetable 蔬菜}, {eat 吃; patient={~}}}
036732	红薯	yam	{ part 部件; PartPosition={embryo 胚}, whole={vegetable 蔬菜}, {eat 吃; patient={~}}}

(3) 对义关系 —— HowNet 把反义之间没有灰度的称之为对义,一般由事件体现,如是非、买卖、教学等。对义关系可通过《同义、反义以及对义组的形成》获得。

(4) 反义关系 —— HowNet 把反义之间有灰度的称为反义,一般由属性值体现,如大小、美丑等。反义关系可通过《同义、反义以及对义组的形成》获得。

除了上述关系外,HowNet 还可以表达一些复杂的组合关系。所谓的复杂概念是以事件为中心,除了事件本身以外还有一个或一个以上的动态角色。

在对 HowNet 的研究中,只需从我们能利用到的角度提取其中一部分,将其转换为对应的 OWL 形式,使其从一个半结构化的语义词典转换为一个高层本体。如果需要的话,还可以对原始文件进行更深层次的研究,并提取出很多其他有价值的关系。例如,采用 Protégé 本体编辑工具,Protégé 是斯坦福大学开发的本体编辑与知识获取工具,带有 OWL 插件的 Protégé 可以支持 OWL 格式的本体编辑与输出,并通过 Racer 工具进行本体的一致性检查和推理。将 HowNet 的概念、义原、动态角色以及词性,分别映射到 OWL 的类、对象属性以及数据类型属性,并通过类的交、并、约束等性质完成复杂概念的定义。

下面说明这些术语在 Protégé 以及 OWL 语言中是如何表示的。



(1) 义原的表示。如图 12.10 所示,将义原的实体类、事件类、属性类、属性值类以及第二特征类的层次结构表示出来。

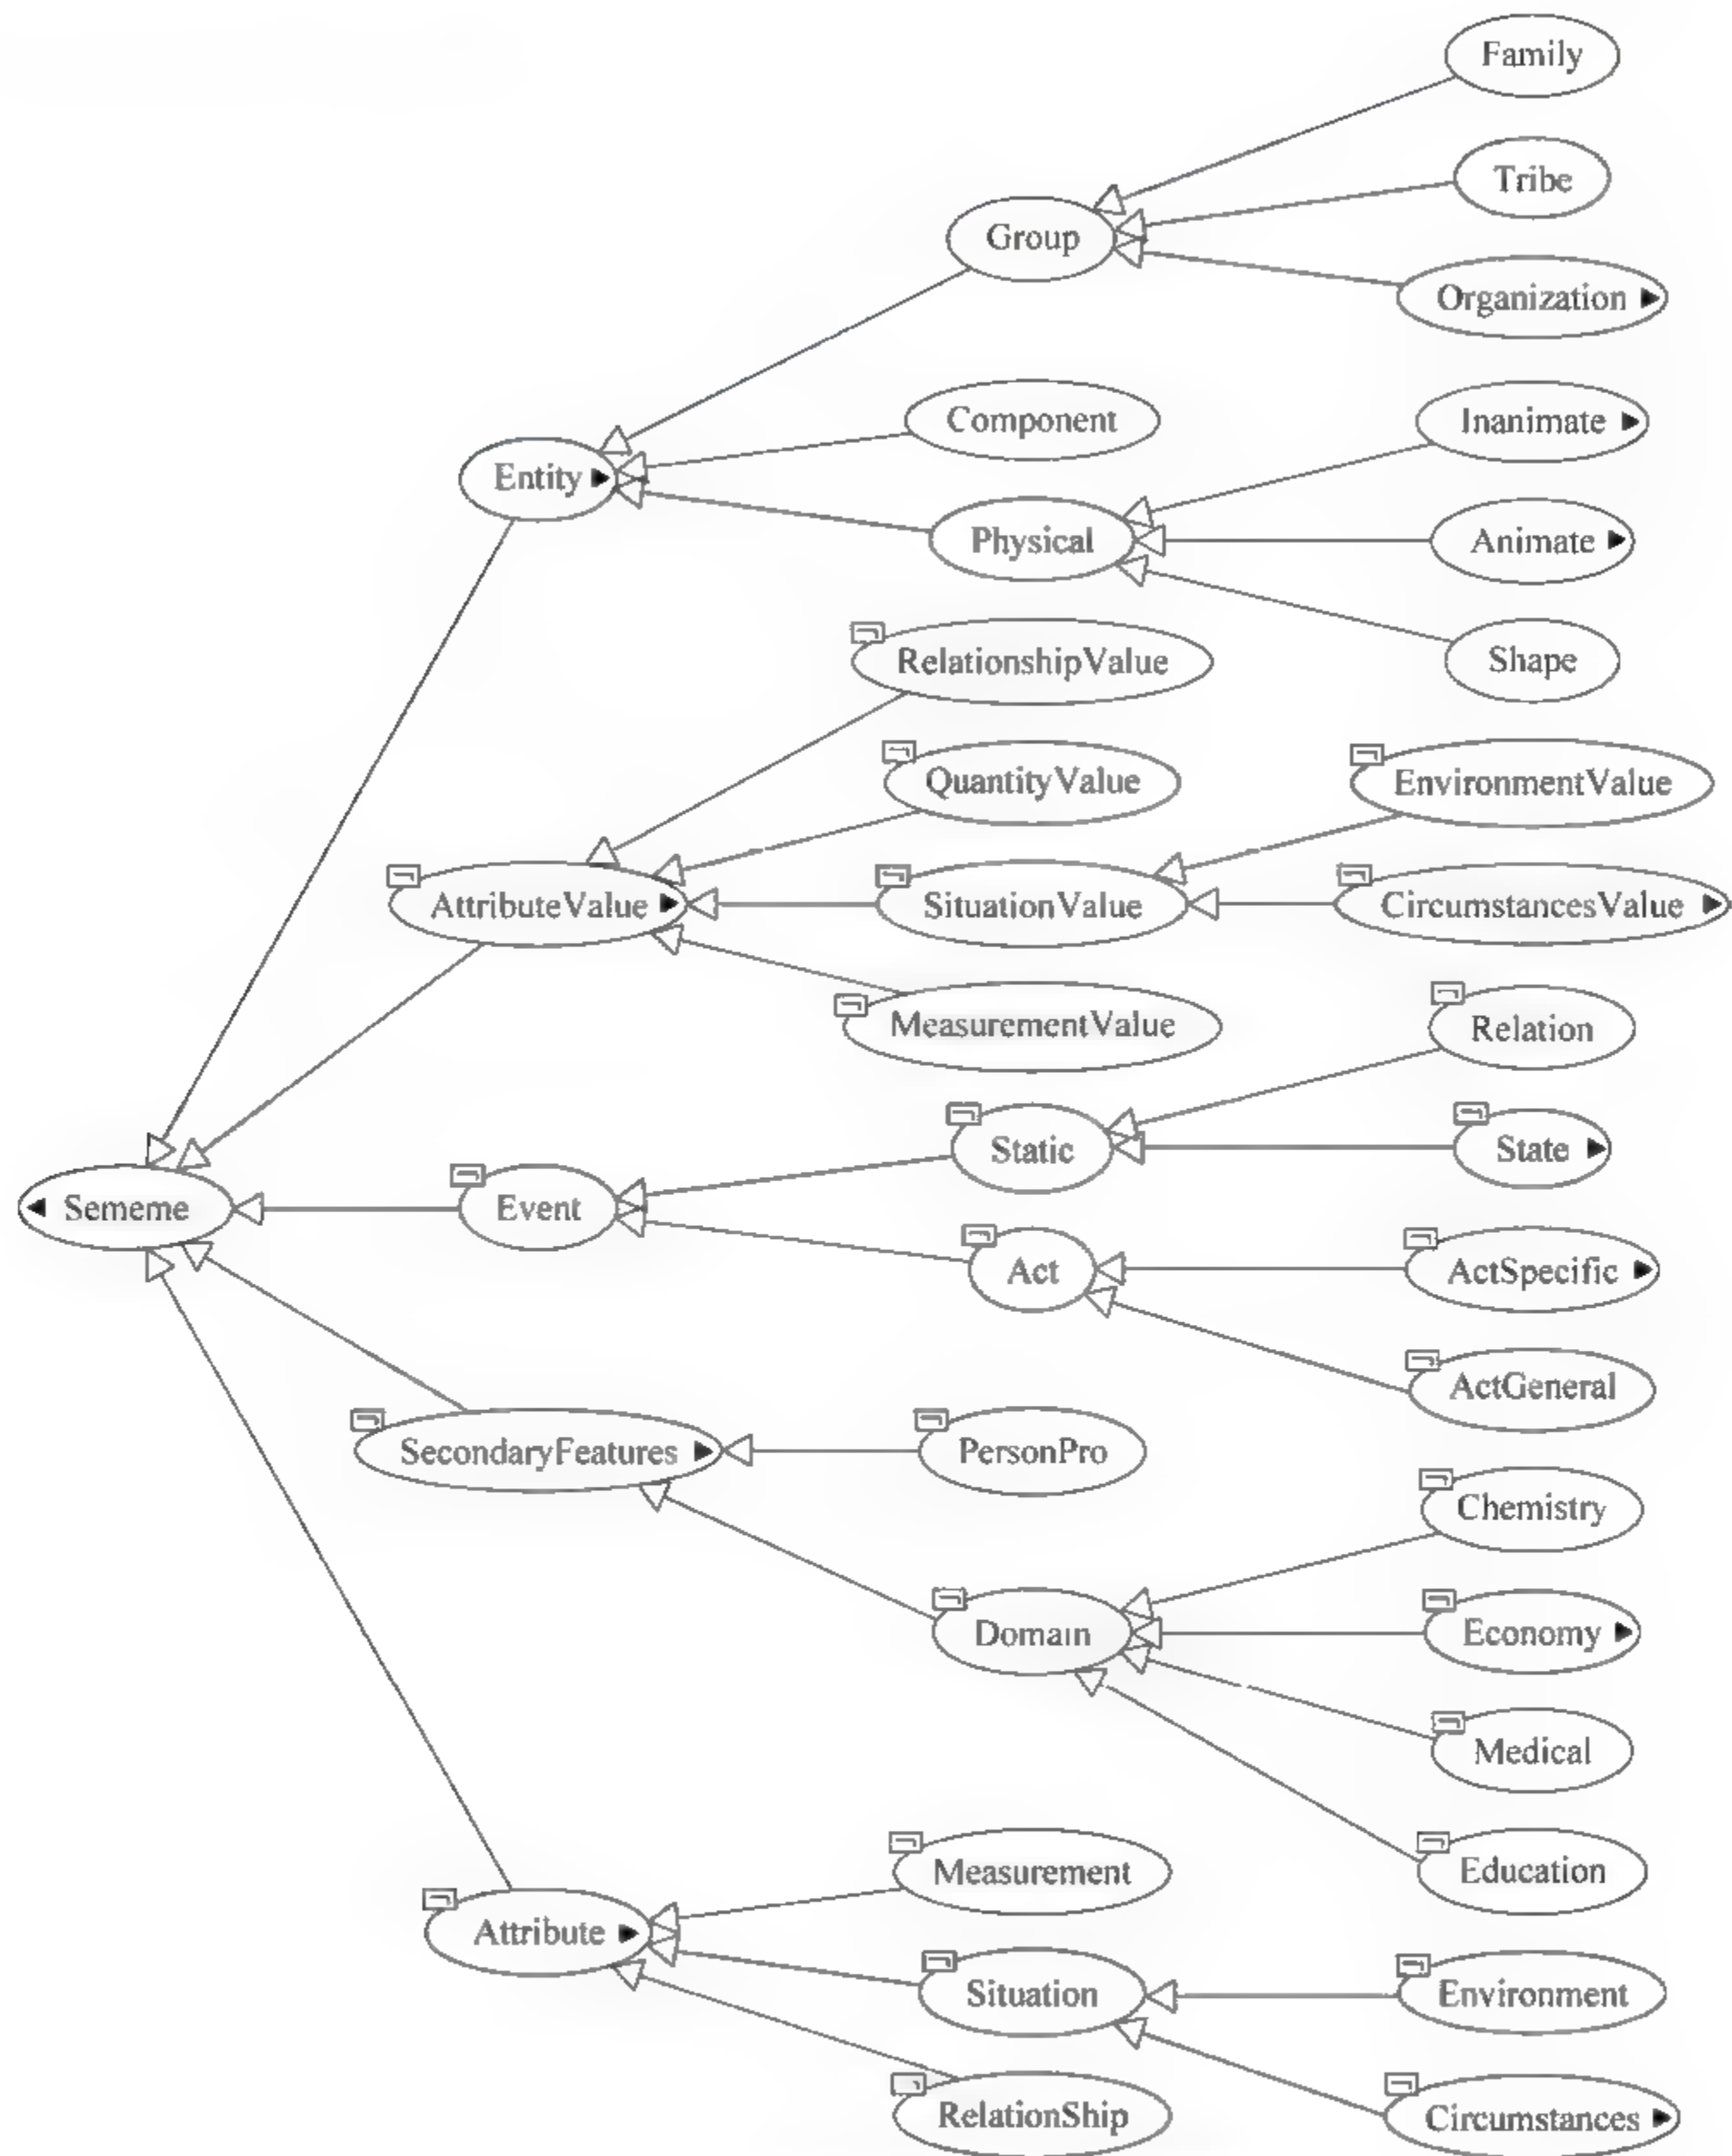


图 12.10 HowNet 义原在 Protégé 的表示

(2) 概念的表示。以“医院”为例,医院的定义项为 DEF—{InstitutePlace|场所; {doctor|医治; location—{~}, content—{disease|疾病}}, domain—{medical|医}},其在 Protégé 中的表示如图 12.11所示,对应的 OWL 如图 12.12 所示。



图 12.11 HowNet 概念“医院”在 Protégé 的表示

```

<owl:Class rdf:ID="hospital">
  <rdfs:subClassOf>
    <owl:Restriction>
      <owl:onProperty rdf:resource="#inverse_of_LOCATION"/>
      <owl:allValuesFrom>
        <owl:Class>
          <owl:intersectionOf rdf:parseType="Collection">
            <owl:Restriction>
              <owl:onProperty rdf:resource="#CONTENT"/>
              <owl:allValuesFrom rdf:resource="#Disease"/>
            </owl:Restriction>
            <owl:Class rdf:about="#Doctor"/>
          </owl:intersectionOf>
        </owl:Class>
      </owl:allValuesFrom>
    </owl:Restriction>
  </rdfs:subClassOf>
  <rdfs:subClassOf>
    <owl:Restriction>
      <owl:onProperty rdf:resource="#DOMAIN"/>
      <owl:allValuesFrom rdf:resource="#Medical"/>
    </owl:Restriction>
  </rdfs:subClassOf>
  <rdfs:subClassOf rdf:resource="#InstitutePlace"/>
  <rdfs:subClassOf rdf:resource="#Word"/>
  <rdfs:comment rdf:datatype="&xsd:string">医院</rdfs:comment>
</owl:Class>
  
```

图 12.12 HowNet 概念“医院”的 OWL 表示

对于概念的表示,还有一种较为简化的方法,即对类似于  $\text{location} - \{\sim\}$  的定义项中带有“ $\sim$ ”的概念,表示动态角色对应的是本身,可以通过将该概念添加到对应的义原的定义中,如可将“hospital”的“inverse\_of\_LOCATION”属性“doctor 医治”转化为“doctor 医治”的“LOCATION”属性,因为“inverse\_of\_LOCATION”同“LOCATION”具有相对的意义。

(3) 动态角色的表示。HowNet 中动态角色的表示如图 12.13 所示。若应用上述提及的简化的概念表示方法,可以不必设置动态角色的逆属性。



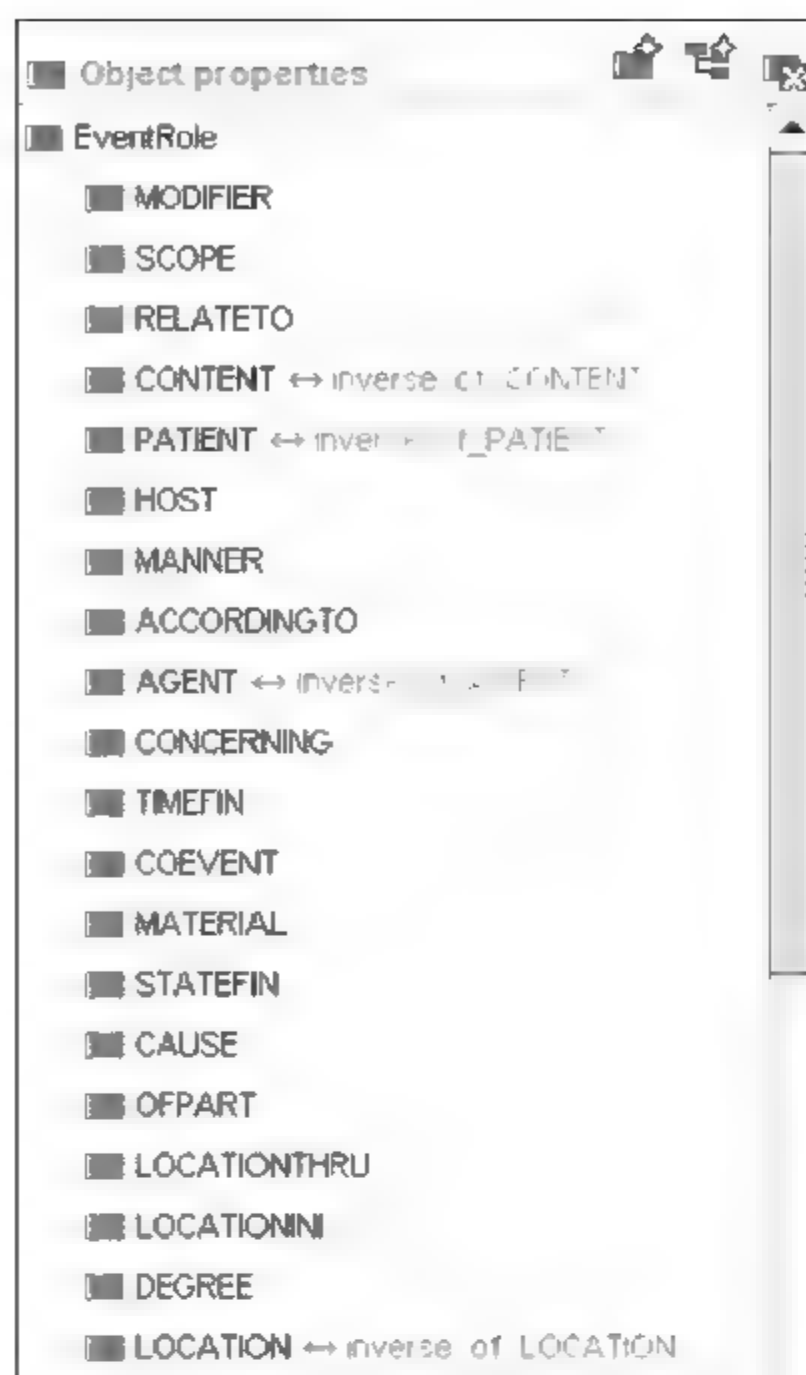


图 12.13 HowNet 动态角色表示为 owl:ObjectProperty

(4) 词性及语言的表示,如图 12.14 所示。

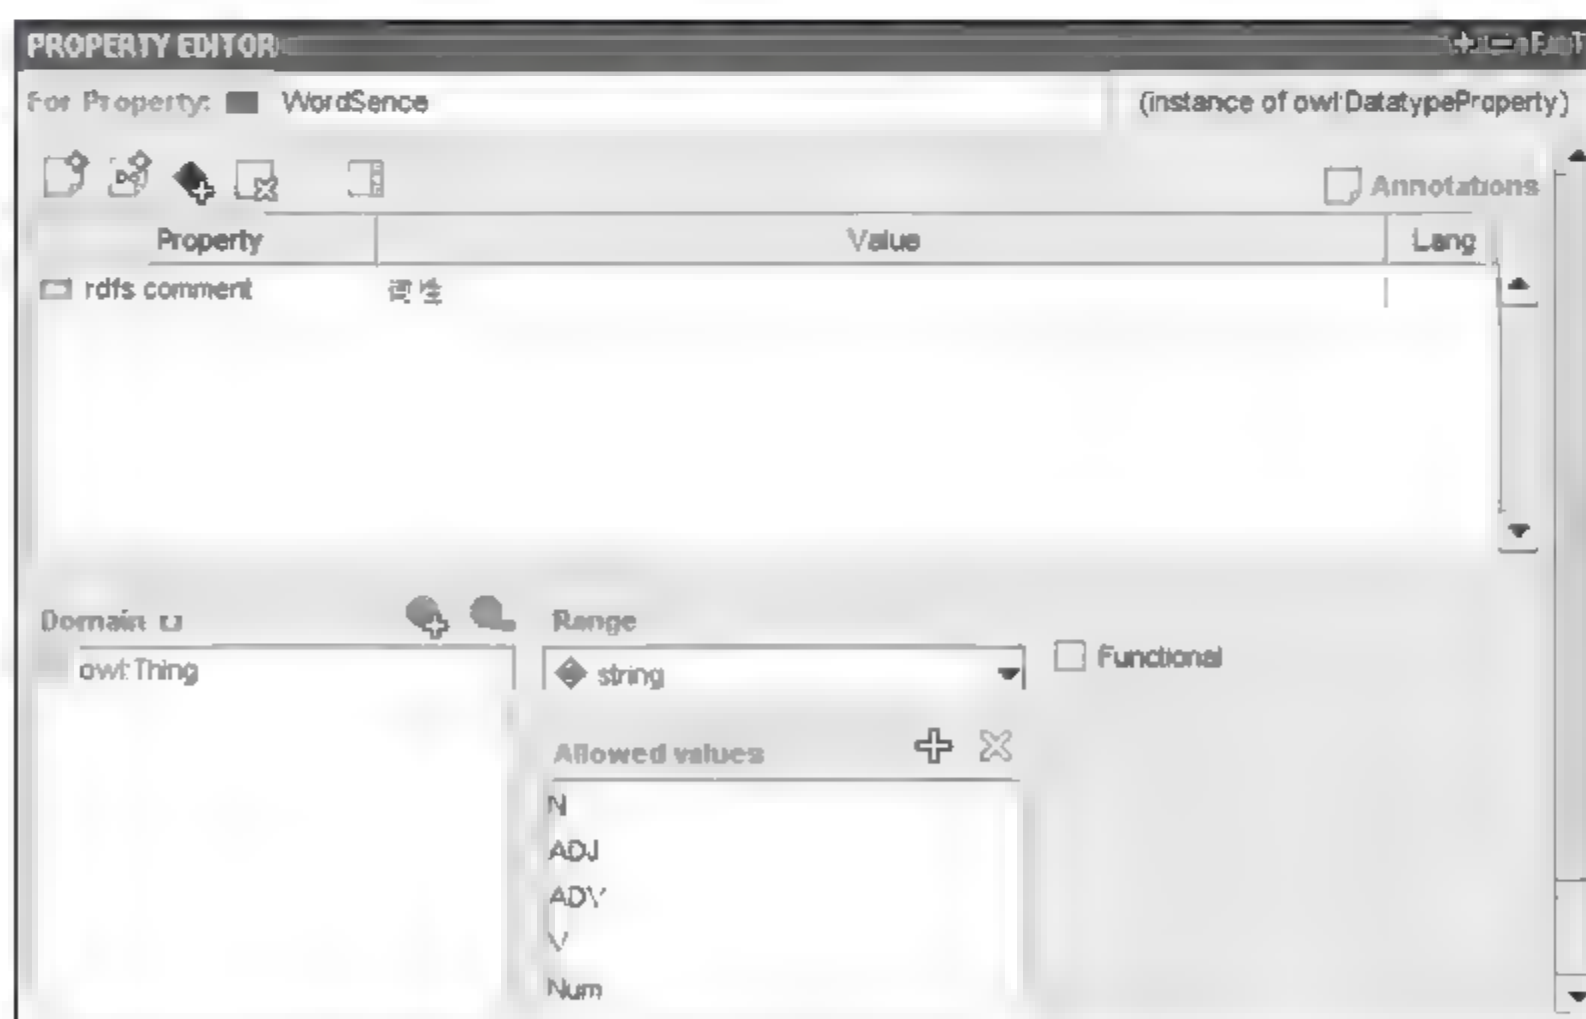


图 12.14 HowNet 词性表示为 owl:DatatypeProperty

## 参 考 文 献

- [1] Medelzon A, Mihaila G, Milo T. Querying the World Wide Web. In: Proceedings of the 4th International Conference on Parallel and Distributed Information System. Miami, 1996. US: ACM Press, 1996, 80-91.
- [2] Agrawal R, Imielinski R. Mining Association Rules. Proceedings of the 20th International Conference on VLDB, September 1994.
- [3] Ahmed S N, Liu H, Sung K K. Handling Concept Drifts in Incremental Learning with Support Vector Machine. In: Proceeding 1999 International Conference Knowledge Discovery and Data Mining (KDD'99). San Diego, CA. Aug. 1999, 437-442.
- [4] Aivassian S A, Bejaeva Z I, Staroverov O V. Classification of Multi-Dimension Observations. Statistic, M, 1974.
- [5] 安磊. 一种基于遗传算法的数据挖掘技术的研究与应用. 南京: 河海大学, 2001.
- [6] Anil K Jain, Robert P W Duin, Mao J. Statistical Pattern Recognition; A review. IEEE Transactions on Pattern Analysis and Machine intelligence, Jan. 2000, 22(1).
- [7] Anderson E. The Irises of the Gaspe Peninsula Bull. Amer. Iris Soc. , 1935, 59, 2-5.
- [8] Krogh A, Vedelsby J. Neural Network Ensembles. Cross Validation and Active Learning. Advances in Neural Information Processing Systems. Tesauro G, Touretsky D, Leen T, eds. , Cambridge, Mass: MIT Press, 1995(7).
- [9] Anthony J Fisher. Practical Parsing of Generalized Phrase Structure Grammars. Computational Linguistics, Volume 15, Issue 3, 139-148, 1989.
- [10] Arning A, Agrawal R, Raghavan P. A Linear Method for Deviation in Large database. In: Proc. of Int. Conf. Data mining and knowledge discovery (KDD'96), Portland, 1996, 164-169.
- [11] Al-Sultan K S, Selim S Z. A global Algorithm for the Fuzzy Clustering Problem. Pattern Recognition. 1993, 26(9); 1357-1361.
- [12] Lerner B, Guterman H, Aladjem M. A Comparative Study of Neural Network Based Feature Extraaction Paradigms. Pattern Recognition Letters. 1998, 19(5,6); 393-402.
- [13] Mobasher B, Srivastava J. Pattern Discovery from World Wide Web Transactions. Technical Report, 1996, 11(6); 17-45.
- [14] Ripley B. Statistical Aspects of Neural Networks. Networks on Chaos: Statistical and Probabilistic Aspects. U Bornndorff-Nielson, J. Jensen and W. Kendal, Chapman and Hall, 1993.
- [15] Barnett V, Lewis T. Outliers in Statistical Data. New York: John Wiley & Sons, 1994.
- [16] Barroso Lucia P, Wilton O Bussab, Martin Knott. Best Linear unbiased prdictor mixed model with incomplete data. Communications in Statistics; Theory and Methods, 1998, 27(1); 121-129.
- [17] Bellman R, Kalaba R, Zadeh L. Abstraction and Pattern Classification. Math. Anal. Appl, 1966, 13, 1-7.
- [18] Benjamin CM, Fung, Ke Wang, Martin Ester. Hierarchical Document Clustering Using Frequent Itemsets, In: Proceedings of the 2003 SIAM International Conference on Data Mining (SDM'03), San Francisco, CA, May 1-3, 2003, 59-70.
- [19] Bernhard Scholkopf, Kah-Kay Sung, et al. , Comparing Support Vector Machines with Gaussian Kernels to Radical Basis Function Classifiers, IEEE Transactions on Signal Processing, 1997, 45(1).



- [20] Bezdek J C. Numerical Taxonomy with Fuzzy Sets. 1974,1(1): 57-71.
- [21] Bezdek J C, Harris J D. Convex Decompositions of Fuzzy Partitions. J. Math. Anal. Appl. ,1979, 67(2):490-512.
- [22] Bezdek J C. A Convergence Theorem for the Fuzzy ISODATA Clustering Algorithms. IEEE Trans, Pattern Anal Mach Intell,1980,2(1): 1-8.
- [23] Bezdek J C, Hathaway R, Sabin M, et al. Convergence theory for fuzzy c-means: Counterexamples and repairs. IEEE Trans. Systems Man, Cybernetics. 1987,17(5): 873-877.
- [24] Bonabeau E, Dorigo M, Theraulaz G. Inspiration for optimization from social insect behaviour, Nature,406,6 July 2000.
- [25] Bonabeau E, Dorigo M, Theraulaz, G. Swarm Intelligence: From Natural to Artificial Systems, Oxford Univ. Press, New York: 1999.
- [26] Borsley R D. Modern Phrase Structure Grammar. Blackwell publishers, 1996.
- [27] Büchner A G, Baumgarten M, Anand S S, et al. Navigation pattern discovery from Internet data. In: WEBKDD'99, KDD Workshop on Web Usage Analysis and User Profiling. Berlin, Springer.
- [28] Carpineto C, Romano G. A Lattice Conceptual Clustering System and Its Application to Browsing Retrieval. Machine Learning, 1996, 24(2): 95-122.
- [29] Camel M, Selim S Z. New Algorithm for Solving the Fuzzy Clustering Problem. Pattern Recognition, 1994, 27(3): 421-428.
- [30] Pykett C E. Improving the efficiency of Sammon's Nonlinear Mapping by Using Clustering archetypes. Electronics Letters 14, 799-800, 1978.
- [31] 蔡伟杰, 张晓辉, 朱建秋等. 关联规则挖掘综述. 计算机工程, 2001, 27(5): 31-32.
- [32] 曹华林. 产品生命周期评价理论及方法研究. 西南民族大学学报, 2004(2): 281-184.
- [33] 常虹, 何丕廉. 神经网络与模糊技术的结合与发展. 计算机应用研究, 2001(5): 4-6.
- [34] Chierchia, G, Ginet S M. Meaning and Grammar. An Introduction to Semantics. MIT Press. 1990.
- [35] 陈英, 徐罡, 顾国昌. 一种本体和上下文知识集成化的数据挖掘方法. 软件学报, 18(10), 2507-2515, 2007.
- [36] 陈禹. IDEF 建模分析与设计方法. 北京: 清华大学出版社. 1999.
- [37] 程继华, 郭建生等. 挖掘所关注规则的多策略方法研究. 计算机学报, 2000, 23(1): 47-51.
- [38] 池太歳. 数据仓库结构设计与实施. 北京: 电子工业出版社, 2005.
- [39] Chomsky N. Aspects of the Theory of Syntax. MIT Press, 1965.
- [40] 仇立克. 领域本体的构建方法及其存储研究, 2006.
- [41] Cohen W W, Singer Y. Context-Sensitive Learning Methods for Text Categorization. In: Proceedings of the Nineteenth International ACM SIGIR Conference on Research and Development in Information Retrieval, 307-315, 1996.
- [42] Cooley R, Mobasher B, Srivastava J. Web mining: Information and Pattern Discovery on the World Wide Web. Proc. IEEE Intl. Conf. Tools with AI, Dec 1997.
- [43] Perrault C R, Grosz B J. Natural-Language Interfaces Annual Review of Computer Science. 1986, 1: 47-82.
- [44] Perrault C R, Grosz B J. Natural-Language Interfaces Annual Review of Computer Science. 1986, 1: 47-82.
- [45] Craig S. Mullins. 数据库管理——实践与过程. 北京: 电子工业出版社, 2003.
- [46] Craven M, Distasquo D, Freitag D et al. Learning to Extract Symbolic Knowledge from the World Wide Web. In Proceedings of the Fifteenth National Conference on Artificial Intelligence (AAAI98), 509-516, 1998.
- [47] Dou D, McDermott D V, Qi P. Ontology Translation on the Semantic Web. Journal of Data



- Semantics,2: 35-57,2005.
- [48] 丁学钧,杨克俭,李虹,等. 数据挖掘中聚类算法的比较研究. 河北建筑工程学院学报,2004,22(03): 125-127.
  - [49] 丁艺明,金远平. 利用降维排序求多维数据模糊聚类. 小型微型计算机系统. 2001,22(1),66-69.
  - [50] Judd D,Mckinley P,Jain A K. Large-Scale Parallel Data Clustering. IEEE Trans. Pattern Analysis and Machine Intelligence,1998,20(8): 226-239.
  - [51] Davies S,Moore A. Bayesian Networks for Lossless Dataset Compression. In Proceeding 1999 International conference Knowledge Discovery and Data Mining (KDD'99). San Diego, CA. Aug. 1999,387-391.
  - [52] Dejing Dou,Paea LePendu. Ontology-Based Integration for Relational Databases. SAC'06, Dijon, France,461-466, April 23-27,2006.
  - [53] De Jong K A. (1975). An Analysis of the Behavior of a Class of Genetic Adaptive Systems. Doctoral dissertation,University of Michigan.
  - [54] 邓英,李明. Web 数据挖掘技术及工具研究. 计算机工程与应用,2001,20: 92-94.
  - [55] Dimitrios Skoutas. Alkis Simitsis. Designing ETL Processes Using Semantic Web Technologies. DOLAP'06,November 10,2006,Arlington, Virginia, USA,67-74.
  - [56] Dong X,Halevey A. Data Integration with Uncertainty. In: Proc. of the 33rd Int'l conf. on Very Large Data Bases (VLDB 2007). New York: ACM Press,2007,687-698.
  - [57] Dong Zhendong,Qiang Dong,HowNet,http://www.keenage.com.
  - [58] 窦永香,赵捧未,秦春秀. 基于本体的对等网语义检索系统. 现代图书情报技术,2007(12).
  - [59] Douglas Baker L, Andrew McCallum. Distributional Clustering of Words for Text Classification. Proceedings of the 21st ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR '98). 1998,96-103.
  - [60] Douglas Fisher: Improving Inference through Conceptual Clustering. 461-465,Proceedings AAAI-87 Sixth National Conference on Artificial Intelligence,July 13-17,Seattle,WA. AAAI Press,1987.
  - [61] Dunn J C. A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters. J Cybern. ,1973,3(3): 32-57.
  - [62] Eberhart R,Kennedy J. A New Optimizer Using Particles Swarm Theory. Proc. Sixth International Symposium on Micro Machine and Human Science (Nagoya, Japan) IEEE Service Center, Piscataway,NJ,1995: 39-43.
  - [63] Edgar Osuna,Robert Freund,Federico Girosi. Training Support Vector Machines: An Application to Face Detection. In: IEEE Conference on Computer Vision and Pattern Recognition,1997,130-136.
  - [64] Levrat E,Bombardier V,Lamotte M et al. Multi-level image segmentation using fuzzy Clustering and Local Membership Variations Detection, IEEE International Conference on Fuzzy Systems, IEEE Press,NY,1992,221-228.
  - [65] Ruspini E H. A new Approach to Clustering. Inform. Control. ,1969,15(1): 22-32.
  - [66] Hruschka E R,Ebecken N F F. Using a Clustering Genetic Algorithm for Rule Extraction from Artificial Neural Networks. Proceedings of The First IEEE Symposium on combinations of Evolutionary Computation and Neural Networks. San Antonio,TX. USA May 2000.
  - [67] Hruschka E R,Ebecken N F F. Applying a Clustering Genetic Algorithm for Rules from Supervised Neural Network. Proceedings of the IEEE International Joint Conference on Neural Networks (IJCNN'2000). Como,Italy,July 2000.
  - [68] Hruschka E R, Ebecken N F F. A Clustering Genetic Algorithm for Extracting Rules from Supervised Neural Networks Models in Data Mining Tasks. In: International Journal of Computers, System and Signals, Special issue: Knowledge Discovery from Structured and Unstructured Data.



- Englebrecht A P ed. December 2000,1(1): 17-29.
- [69] Hruschka E R, Ebecken N F F. Credit Approval by a Clustering Genetic Algorithm. In: Data Mining II, Ebecken N, Brebbia C A ed. Proceedings of the Data Mining 2000 Conference, Cambridge University, Cambridge, UK, July 2000, 403-413.
  - [70] Ester M et al. A density-Based Algorithm for Discovering Clusters in Large Spatial Database with noise. The 2nd International Journal Conference on Knowledge Discovery and Data Mining, Poland, 1996.
  - [71] Hodson F R. Numerical Typology and Prehistory Archaeology. In: Mathematics in the Archaeological and Historical Sciences, Hodson F R, Kendall D G, Tautu P A ed. University Press, Edimburg, 1971.
  - [72] 范九伦, 裴继红, 谢维信. 基于可能性分布的聚类有效性. 电子学报, 1998, 26(4): 113-115.
  - [73] Fayyad U M, Djorgovski S G, Weir N. Automating the Analysis and Cataloging of Sky Surveys, In: Advances in Knowledge Discovery and Data Mining, AAAI Press 1996, 471-493.
  - [74] Fayyad U M, Piatetsky-Shapiro G and Smyth P. From Data Mining to Knowledge Discovery: An Overview, Advances in Knowledge Discovery and Data Mining, AAAI/MIT Press, 1996.
  - [75] 飞思科技产品研发中心. Oracle9i 数据仓库构建技术. 北京: 电子工业出版社, 2003.
  - [76] Feldman R, Mining Unstructured Data, KDD99 Tutorial Notes, San Diego CA USA.
  - [77] 冯玉才, 冯剑琳. 关联规则的增量式更新算法. 软件学报, 1998, 9(4): 301-306.
  - [78] Fernando Berzal, Cubero Juan-Carlos, et al. TBAR: An efficient method for association rule mining in relational databases. Data & Knowledge Engineering, 2001, 37: 47-64.
  - [79] Flake R H, Turner B L. Numerical Classification for Taxonomic Problems. Theoret Biol, 1968(20): 260-270.
  - [80] Freund Y, Schapire R E. A Decision-Theoretic Generalization of On-Line Learning and An Application to Boosting. Computer and System Sciences, 1997, 55(1): 119-139.
  - [81] Miligan G W. Clustering Validation: Results and Implications for Applied Analyses, In: Clustering and Classification, Araboe P, Hubert L J, DeSoete G. ed, World Scientific, Publishing Co Pte, Singapore, 1996, 341-373.
  - [82] Liu G L. Introduction to Combinatorial Mathematics. McGraw Hill, 1998.
  - [83] 高飞, 谢维信. 互联网上的数据挖掘. 计算机科学, 2001, 28(5): 81-84.
  - [84] 高新波, 谢维信. 模糊聚类理论发展及应用的研究进展. 科学通报, 1999, 21: 2241.
  - [85] Gehrke J, Ramakrishnan R, Ganti V Rainforest: A framework for Fast Decision Tree Construction of Large Datasets. In: Proceeding 1998 International conference Very Large Data Bases (VLDB'98). New York, Aug 1998, 416-427.
  - [86] Gitman I, Levine M. An Algorithm for Detecting Unimodal Fuzzy Sets and its Application as a Clustering Technique. IEEE Trans. Comp. 1970, C-19: 583-593.
  - [87] Goldberg D E. Genetic Algorithm in Search, Optimization and Machine Learning. Reading, Addison-Wesley, 1989.
  - [88] 龚菲. 产品生命周期识别模型研究: [学位论文]. 南京: 南京航空航天大学, 2003.
  - [89] Grigoris Antoniou, Frank van Harmelen. A Semantic Web Primer. MIT Press, 2004.
  - [90] Guha S, et al. CURE: An Efficient Clustering Algorithm for Large Databases, In: Conf. of ACM SIGMOD 1998, 73-84.
  - [91] Gunderson R. Application of Fuzzy ISODATA Algorithms to Star Tracker pointing System. In: Proc. 7th Triennial World IFAC Congress, Helsinki, 1978, 1319-1323.
  - [92] 郭东伟. 遗传算法运行机理的研究: [博士学位论文]. 吉林大学, 2002.
  - [93] 郭明, 郑惠莉. 用数据挖掘法分析电信客户流失. 现代通信, 2005(03): 7-9.



- [94] 郭秀娟. 数据挖掘方法综述. 吉林建筑工程学院学报, 2004, 21(01): 49-53.
- [95] Frigui H, Krishnapuram R. A Robust Competitive Clustering Algorithm with Applications in Computer Vision. IEEE Trans. Pattern Analysis and Machine Intelligence, 1999, 21(5): 450-465.
- [96] Han Jianwei, Kamber M. Data Mining: Concepts and Techniques, Morgan Kaufmann Publishers, 2000.
- [97] 韩家炜, 孟晓峰, 王静, 等. Web挖掘研究. 计算机研究与发展, 2001, 38(4): 405-410.
- [98] 何丕廉, 侯越先. 模糊聚类神经网络的非对称学习算法. 计算机研究与发展, 2001, 38(3): 296-301.
- [99] 贺仲雄. 模糊数学及其应用. 天津: 天津科学技术出版社, 1984, 76-185.
- [100] Heckerman D, Geiger D, Chickering D M. Learning Bayesian Networks: The Combination of Knowledge and Statistical Data. Machine Learning. 1995, 20: 197-243.
- [101] Heike Hofmann, Arno P J M. Siebes et al. Wilhelm, Visualizing Association Rules with Interactive Mosaic plots, Proceedings of the sixth ACM SIGKDD international conference on Knowledge Discovery and Data Mining, 227-235, Boston, MA USA, 2000.
- [102] Helena Ahonen-Myka, Oskari Heinonen, Mika Klemettinen et al. Finding Co-occurring Text Phrases by Combining Sequence and Frequent Set Discovery. Proceedings of 16th International Joint Conference on Artificial Intelligence IJCAI-99 Workshop on Text Mining: Foundations, Techniques, Applications, ed. R. Feldman, 1-9.
- [103] Holland J H. Adaptation in natural and artificial system. Ann Arbor: University of Michigan, 1975.
- [104] 胡侃, 夏绍纬. 基于大型数据仓库的数据采掘: 研究综述. 软件学报, 1998, 1(9).
- [105] 胡鹤. 本体方法及其时空推理应用研究. [博士学位论文]. 吉林大学, 2004.
- [106] 胡可云, 陆玉昌, 石纯一. 基于概念格的分类和关联规则的集成挖掘方法. 软件学报, 2000, 11(11): 1478-1484.
- [107] 黄岚. 物流配送中的车辆路由算法的研究: [博士学位论文]. 吉林大学, 2003.
- [108] 黄添强. 基于空间数据挖掘的环境调控空间决策支持系统研究. 福州: 福州大学, 2002.
- [109] 黄曾阳. 概念层次网络理论. 北京: 清华大学出版社, 1998.
- [110] <http://www.keenage.com>.
- [111] <http://www.w3.org>.
- [112] <http://www.w3.org/RDF>.
- [113] <http://infolab.stanford.edu/SKC>.
- [114] <http://swoogle.umbc.edu>.
- [115] <http://www.w3.org/2006/03/wn/wn20>.
- [116] Gath I, Geva A B. Unsupervised Optimal Fuzzy Clustering. IEEE Trans. Patt. Anal. Machine Intell, 1989, 11: (7).
- [117] Lin I Y, Huang X M, Chen M S. Capturing User Access Patterns in the Web for Data Mining. In: Proceedings of the 11th IEEE International Conference Tools with Artificial Intelligence. Chicago, 1999. US: ACM Press, 1999, 345-348.
- [118] István Bátori, Stefan Marok. Efficiency Considerations for LFG-parsers: incremental and Table-Lookup Techniques. International Conference On Computational Linguistics Proceedings of the 12th conference on Computational linguistics, Budapest, Hungary. 1988(1): 25-27.
- [119] Han J, Kamber M. Data Mining: Concepts and Techniques. Beijing: Higher Education Press, Morgan Kaufmann Publishers, 2001. 25-40.
- [120] Mao J, Mohiuddih K, Jain A K. Parimonious Network Design and Feature Selection through Node Prunning. Proc., 12th Int'l Conf. Pattern on Recognition, Oct 1994, 622-624.
- [121] Mao J, Jain A K. A Self-Organizing Network for Hyper-Ellipsoidal Clustering (HEC). IEEE



- Trans. On neural networks,1996,7(1): 16-29.
- [122] Dunn J C. Indices of Partition Fuzziness and Detection of Clusters in Large Data Sets. In: Fuzzy Automata and Decision Processes. New York: Elsevier,1977.
  - [123] Sammon J W. A nonlinear mapping for data structure analysis. IEEE Trans. on Computers,1969, 18: 401-409.
  - [124] Quinlan J R. Bagging, Booting and C4. 5. In Proc of 13th. National Conference on Artificial Intelligence Portland,1996,725-730.
  - [125] Jaideep Srivastava, Robert Cooley, Mukund Deshpande, Pang-Ning Tan, Web Usage Mining: Discovery and Applications of Usage Patterns from Web Data(2000). SIGKDD Explorations, Vol. 1, Issue 2,2000.
  - [126] 吉根林. 聚类算法研究:[硕士学位论文]. 南京师范大学,2004.
  - [127] 贾琳,李明. 基于数据挖掘的电信客户流失模型的建立与实现. 计算机工程与应用,2004, 10(185).
  - [128] Jiawei Han, Jian Pei, Yiwen Yin. Mining Frequent Patterns without Candidate Generation. In: Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data, Dallas, 2000. US: ACM Press,2000,243-252.
  - [129] 敬宗儒. 基于 Semantic Web 的语义检索模型的研究:[硕士学位论文]. 华东师范大学,2007.
  - [130] John Davies, Dieter Fensel, Frank Van Harmelen. Towards the Semantic Web: Ontology-driven knowledge Management. John Wiley & Sons Ltd. 2003.
  - [131] John Poole, Dan Chang. 公共仓库元模型数据仓库集成标准导论. 北京:机械工业出版社,2004.
  - [132] Jorg-Uwe Kietz, Raphael Volz, Alexander Maedche. Extracting a Domain-Specific Ontology from a Corporate Intranet. Proceedings of the Fourth Conference on Computational Natural Language Learning and of the Second Learning Language in Logic Workshop, Lisbon. 2000.
  - [133] Bharat K, Henzinger M. Improved Algorithms for Topic Distillation in a Hyperlinked Environment. In: Proceedings of the 21st ACM-SIGIR International Conference on Research and Development in Information Retrieval. Melbourne. 1998. US: ACM Press,1998.104-111.
  - [134] 康晓东. 基于数据仓库的数据挖掘技术(第一版). 北京:机械工业出版社,2003.
  - [135] Kargupta H, Hamzaoglu I, Stafford B. Scalable, Distributed Data Mining Using An Agent Based Architecture. In: Conf on Knowledge Discovery and Data Mining,211-214, August 1997.
  - [136] Karypis G, Han E, Kumar V. CHAMELEON: A Hierarchical Clustering Algorithm Using Dynamic Modeling, IEEE Computer, Aug 1999,32(8): 68-75.
  - [137] Rose K. Deterministical Annealing for Clustering, Compression, Classification, Regression and Related Optimization Problems. Proc IEEE. 1998,86: 2210-2239.
  - [138] Ke Wang, Liu Tang, Jiawei Han. Top Down FP-growth for Association Rule Mining. In: Pacific-Asia Conference on Knowledge Discovery and Data Mining. Taipei. 2002. DE: Springer Press, 2002. 334-340.
  - [139] Kohonen T. Self Organization and Associative Memory. Berlin, Germany: Springer-Verlag,1989.
  - [140] Kohonen. T. Self-Organizing Maps. Berlin, Springer,2001.
  - [141] Krishma K, Murty M N. Genetic K-means Algorithm. IEEE Transactions on System, Man and Cybernetics, Part B,1999,29(3): 433-439.
  - [142] Krista Lagus. Text Mining with the WEBSOM. Helsinki University of Technology, Finland,2000.
  - [143] Lewis D D, Schapore R E, Callan J P, and Papka R. Training algorithms for linear text classifiers. In Proceedings of the Nineteenth International ACM SIGIR Conference on Research and Development in Information Retrieval,1996. 298-306.
  - [144] Li Deyi, Di Kaichang, Shi Xuemei. Mining Association Rules with Linguistic Cloud Models. 软件学



- 报,2000,11(2): 143-158.
- [145] 李德仁,王树良,李德毅等. 论空间数据挖掘和知识发现的理论与方法. 武汉大学学报(信息科学版), 2002,27(3),221-233.
- [146] Li dong,Huang linpeng. A Framework for Ontology-Based Data Integration. Internet Computing in Science and Engineering,2008. ICICSE '08. International Conference on,28-29 Jan. 2008. 207-214.
- [147] 李剑,宋靖宇,钟华. 基于本体的异构信息集成查询划分及转换. 软件学报,2007,18(10): 2495-2506.
- [148] 李学明,刘勇国等. 扩展型关联规则与原关联规则及其若干性质. 计算机研究与发展,2002,39(12): 1740-1750.
- [149] 梁唯溪,黎志成. 产品生命周期定性模拟原形系统的研究. 华中科技大学学报(自然科学版),2003(10): 99-101.
- [150] 林杰斌. 数据挖掘与 OLAP 理论与实务. 北京: 清华大学出版社,2003.
- [151] Liu B,Hsu W,Ma Y. Integrating Classification and Association Rule Mining. In: Proceeding 1998 International conference Knowledge Discovery and Data Mining(KDD'98). New York. Aug. 1998. 80-86.
- [152] 刘俊凤. 语义 Web 环境下基于 Ontology 的信息检索研究. 情报科学,2006,4: 566-570.
- [153] 刘红岩,陈 剑,陈国青. 数据挖掘中的数据分类算法综述. 清华大学学报(自然科学版),2002,42(6): 727-730.
- [154] 刘云,刘东苏. 基于 Web 的数据仓库与数据挖掘技术. 情报理论与实践,2001,24(4): 289-290.
- [155] Loh W Y, Vanichsetakul N. Tree-structrued Classification generalized Discriminant Analysis. Journal of American Statistical Association. 1988,83,715-728.
- [156] Loh W Y,Shih Y S. Split Selection methods for Classification Trees. Statistica Sinica. 1997, 815-840.
- [157] 鲁川. 现代汉语的语义网络. <http://www.hnc.com>.
- [158] 陆建江. 加权关联规则挖掘算法的研究. 计算机研究与发展,2002,39(10): 1281-1286.
- [159] 陆汝钤. 人工智能. 北京: 科学出版社,1996.
- [160] 陆汝占等. 从汉语句子中提取逻辑函子的一种方法,软件学报,1998,9(6).
- [161] Luttrell S P. Partitioned mixture distribution; An Adaptive Bayesian Network for Low-Level Image processing. IEEE Proceedings on Vision,Image and Signal Processing,1994,141(4): 251-260.
- [162] Kaufman L., Rousseeuw R J. Finding Groups in Data—An Introduction to Cluster Analysis, Wiley Series in Probability and Mathematical Statistics, John Wiley & Sons,1990.
- [163] Funk M,Appel R D,Roch D et al. Knowledge acquisition in expert system assisted diagnosis; a machine learning approach,Proceedings of the AIME-87, Springer Verlag,1987. 99-103.
- [164] Windham M P. Cluster Validity for Fuzzy Clustering algorithms. Fuzzy Sets Syst. 1980,3: 1-9.
- [165] Windham M P,Bock H,Walker H F. Clustering Information from Convergence rate. In Proc. 2nd Conf. Int. Federation Classification Soc (Washington DC),1989.
- [166] Spiliopoulou M,Mobasher B,Berendt B. A Framework for the Evaluation of Session Reconstruction Heuristics in Web Usage Analysis. Inform Journal of Computing,2002,14(4): 204-208.
- [167] Mali U,Bandyopadhyay S. Genetic Algorithm-Based Clustering Technique. Pattern Recognition, 2000,33(9): 1455-1465.
- [168] 马军,邵陆. 模糊聚类计算的最佳算法. 软件学报,2001,12(4),578-581.
- [169] MacQueen J. Some Methods for Classification and Analysis of Multivariate Observations. In: Proceedings of the 5th Berkeley Symposium on Mathematics statistic Problem,1967,1: 281-297.
- [170] Madria S K,Bhowmick S S,W K Ng,E P Lim. Research Issues in Web Data Mining. Proceedings of the 1st International Conference on Data Warehousing and Knowledge Discovery (DAWAK' 99).



In conjunction with DEXA 99. Florence, Italy, August 30, Sept 1, 1999.

- [171] Makoto Iwayama and Takenobu Tokunaga. Cluster-Based Text Categorization: A Comparison of Category Search Strategies. In SIGIR 95, 273-281, 1995.
- [172] Mark Dixon. An Overview of Document Mining Technology, <http://citeseer.nj.nec.com/dixon97overview.html>.
- [173] Martin D, Burstein M, Hobbs J. OWL-S: Semantic markup for Web services. 2006. <http://www.ai.sri.com/daml/services/owl-s/1.2/overview>.
- [174] 毛国君. 数据仓库的质量管理问题和方法. 计算机科学, 2003.
- [175] Martin T Hagan, Howard B Demuth, Mark H Beale. 神经网络设计. 北京: 机械工业出版社, 2002.
- [176] McGuinness D L, van Harmelen F. OWL Web Ontology Language Overview. World Wide Web Consortium (W3C) Recommendation. 2004. <http://www.w3.org/TR/owl-features>.
- [177] Mehta M, Agrawal R, Rissanen J. SLIQ: A Fast Scalable Classifier for Data Mining. In Proceeding 19, 96 International conference Extending Database Technology (EDBT'96). Avignon, France. Mar. 1996.
- [178] Mehta M, Rissanen J, Agrawal R. MDL-Based Decision Tree Pruning. In Proceedings of KDD'98.
- [179] 孟小峰. Web 数据管理研究综述. 计算机研究与发展, 2001, 38(4): 385-394.
- [180] Meretakis D, Wilthrich B. Extending Naïve Bayes Classifiers Using Long Itemsets. In Proceeding 1999 International conference Knowledge Discovery and Data Mining (KDD'99). San Diego. Aug. 1999. 165-174.
- [181] Michalewicz Z. Genetic Algorithms + Data Structure = Evolution Programs. Springer-Verlag, Berlin.
- [182] Michael Steinbach, George Karypis, Vipin Kumar. A Comparison of Document Clustering Techniques, Text Mining Workshop, KDD, 2000.
- [183] Miller J. Semantics and Syntax. CUP. 1992.
- [184] Mitchell T. "Machine Learning and Data Mining" Communications of the ACM, 42, No. 11, November, 1999.
- [185] Monmarché N, Slimane M, and Venturini G. On Improving Clustering in Numerical Databases with artificial ants. Floreano D, Nicoud J D, Mondala F, ed. Lecture Notes in Artificial Intelligence, Swiss Federal Institute of Technology, Lausanne, Switzerland, Springer-Verlag, 626-635, 13-17 Sept. 1999.
- [186] Mu-Chun Su, Nicholas DeClaris, Ta-Kang Liu. Application of Neural Networks in Cluster Analysis, 1997. 1-6.
- [187] Chen M S, Han J, Yu P S. Data Mining: An Overview from a Database Perspective. IEEE Trans. Knowledge and Data Eng., Dec. 1996, 866-883.
- [188] Pal N R, Bedzek J C. On Cluster Validity for Fuzzy c-means model. IEEE Trans Fuzzy System, 1995, 3(3): 370-379.
- [189] Etzioni O, Hanks S. Efficient Information Gathering on the Internet. Foundations of Computer Science, 1996, 12(4): 234-243.
- [190] Romero O, Abelló A. Generating Multidimensional Schemas from the Semantic Web. In Proc. of CAiSE Forum'07, Poster, 2007, 247, 69-72.
- [191] Oscar Romero, Alberto Abelló. Automating Multidimensional Design from Ontologies. DOLAP'07, November 9, Lisboa, Portugal, 1-8, 2007.
- [192] 欧阳为民, 郑诚, 蔡庆生. 数据库中加权关联规则的发现. 软件学报, 2001, 12(4): 612-619.
- [193] 欧阳为民等. 国际知识发现与数据发掘工具评述. 计算机科学, 2001, 28(3): 101-108.



- [194] 潘正君,康立山,陈毓屏. 演化计算. 北京:清华大学出版社,1998.
- [195] Parsopoulos K E, Vrahatis M N. Recent Approaches to Global Optimization Problems Through Particle Swarm Optimization, *Natural Computing*, 2002, 1(2 3): 235-306.
- [196] 裴韬,周成虎,骆剑承等. 空间数据知识发现研究进展评述. *中国图象图形学报*, 2001, 6A(9), 854-860.
- [197] Pitkow. In Search of Reliable Usage Data on the WWW. In: *Human Factors in Computing Systems, CHI'97 Conference Proceedings*. Atlanta, 1997. US: ACM, 1997. 3-10.
- [198] Philip A Bernstein, Laura M Haas. Information Integration in the Enterprise. *Communications of the ACM*, 2008, 51(9), 72-79.
- [199] Pregibon D, Elder J. A Statistical Perspective on Knowledge Discovery in Databases, In: *Advances in Knowledge Discovery and Data Mining*. MIT Press, 1996.
- [200] Popchev I P, Peneva V G. Preliminary Information Processing with Cluster Analysis. Report Annual 1985 of Conferencia Cientifica of ININTIF, Academia de Ciencias de Cuba, tomo 1, Octubre 1985.
- [201] 戚桂杰,陈丹,王凯平等. 数据挖掘中原始数据质量问题的统计处理. *山东大学学报(理学版)*, 2005, 40(03): 57-61.
- [202] 齐佳音,舒华英. 客户价值评价、建模及决策. 北京:北京邮电大学出版社,2005.
- [203] Qi ZM, Zheng Y. An Approach for Domain Ontology-Based Semantic Retrieval. 2008 China-Ireland International Conference on Information and Communications Technologies Proceeding. Beijing China. 185-189.
- [204] Quagliarella D. Genetic Algorithm and Evolution Strategy in Engineering and Computer science: Recent Advances and Industrial Application. Chichester Wiley, 1998.
- [205] Agrawal R, Imielinski T, Swami A. Mining Association Rules between Sets of Items in Large Databases. In: *Proceedings of the ACM SIGMOD Conference on Management of Data*. Washington, 1993. US: ACM Press, 1993, 207-216.
- [206] Agrawal R, Srikant R. Fast Algorithms for Mining Association Rules in Large Database. Technical Report FJ9839, IBM Almaden Research Center, 1994, 11(5): 487-499.
- [207] Lee R C T, Slagle J R, Blum H. A triangulation method for the sequential mapping of points from N-space to two-space. *IEEE Trans. on Computers*. 1977, 26: 288-292.
- [208] Cooley R, Mobasher B, Srivastava J. Data Preparation for Mining World Wide Web Browsing Patterns. *Knowledge and Information System*, 1999, 5(1): 5-32.
- [209] Cooley R, Mobasher B, Srivastava J. Web Mining: Information and Pattern Discovery on the World Wide Web. *Tools with Artificial Intelligence*, 1997, 12(5): 558-567.
- [210] 格罗思. 数据挖掘——构筑企业竞争优势. 西安:西安交通大学出版社,2001.
- [211] neal R. Bayesian Learning for Neural Networks. New York: Spring Verlag, 1996.
- [212] Duda R O. Pattern Classification and Scene Analysis. New York: Wiley, 1973.
- [213] Ralph Kimball, Margy Ross 等著. 数据仓库工具箱: 维度建模的完全指南(第二版). 北京:电子工业出版社, 2003.
- [214] Lawrence R, Almasi G, Kotlyar V, et al. Personalization of Supermarket Product Recommendations. *Data Mining and Knowledge Discovery*, 2001, 7(3): 11-32.
- [215] Ralph Kimball, Laura Reeves, Margy Ross. 数据仓库生命周期工具箱: 设计、开发和部署数据仓库的专家方法. 北京:电子工业出版社, 2004.
- [216] Rastogi R, Shim K. PUBLIC: A decision Tree Classifier that Integrated Building and Pruning. In: *Proceeding 1998 International conference Very Large Data Base(VLDB'98)*. New York. 1998: 404-415.



- [217] Raymond Kosala, Hendrik Blockeel. Web Mining Research: A Survey, SIGKDD Explorations, 2000, 2(1), 1-15.
- [218] Reza Langari, Liang Wang. Fuzzy Models, Modular Networks, and Hybrid learning. Fuzzy Sets and Systems, 1996.
- [219] Ruspini E. Numerical Methods for Fuzzy Clustering. Inf Sci, 1970, 2: 319-350.
- [220] Russell S, Norvig P. Artificial Intelligence: A Modern Approach. Englewood Cliffs, NJ: Prentice-Hall. 1995.
- [221] Brin S, Page L. The Anatomy of a Large-scale Hyper Textual Web Search Engine. In: Proceedings of the 7th ACM-WWW International Conference. Brisbane. 1998. US: ACM Press, 1998. 107-117.
- [222] Brin S, Rastogi R, Shim K. Mining Optimized Gain Rules for Numeric Attributes. Knowledge and Data Engineering, 2003, 15(2): 324-338.
- [223] Chen S, Cowan C F N, Grant P M. Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks. IEEE Transactions on Neural Networks, 1991, 2(2): 302-309.
- [224] Mishra S K, Raghavan V V. An Empirical Study of the Performance of Heuristic Methods for Clustering. Pattern Recognition in Practice, E. S. Gelsema and L. N. Kanal, eds., North-Holland, 1994, 425-436.
- [225] 桑琳, 邹开其. 基于模糊聚类分析的模糊神经网络结构的优化. 计算机工程与应用, 2001, 13: 65-67.
- [226] Schlimmer J C, Fisher D A. Case Study of Incremental Concept Induction. In Proceeding 5th National Conference Artificial Intelligence (AAAI'86), San Mateo: Morgan Kaufmann, 1986. 496-501.
- [227] Silva J, Mexia J, Coelho A, Lopes G. Document Clustering and cluster Topic Extraction in Multilingual Corpora, in proceedings of 2001 IEEE International Conference on Data Mining, San Jose, California.
- [228] Sirin E, Parsia B, Grau, B et al. Pellet: A Practical OWL-DL Reasoner. Journal of Web Semantics (Elsevier), 2007, 5(2): 51-53.
- [229] Shafer J, Agrawal R, Mehta M. SPRINT: A Scalable Parallel Classifier for Data Mining. In Proceeding 1996 International Conference Very Large Data Bases (VLDB'96). Bombay, India. Sept. 1996. 544-555.
- [230] 邵军力, 张景, 魏长华. 人工智能基础. 北京: 电子工业出版社, 2000.
- [231] 史东辉, 张春阳, 蔡庆生. 小型微型计算机系统. 2001, 22(10): 1234-1236.
- [232] 史忠植. 知识发现. 北京: 清华大学出版社, 2002.
- [233] Simon Haykin 编著. 神经网络原理. 叶世伟, 史忠植译. 北京: 机械工业出版社, 2004.
- [234] 苏新宁. 电子政务技术(第一版). 北京: 国防工业出版社, 2003.
- [235] 宋擒豹, 沈钧毅. Web 页面和客户群体的模糊聚类算法. 小型微型计算机系统, 2001, 22(2): 229-231.
- [236] 宋炜等. 语义网简明教程. 北京: 高等教育出版社, 2004.
- [237] Srinivas M, Patnaik L M. Adaptive Probability of Crossover and Mutation in Genetic Algorithms. IEEE Trans on SMC., 1994, 24(4): 656-667.
- [238] Guha S, Rastogi R, Shim K. ROCK: A Robust Clustering Algorithm for Categorical Attributes. Proc. 15th Int'l Conf. Data Eng., IEEE CS Press, Los Alamitos, Calif., 1999. 512-521.
- [239] Guha S, Rastogi R, Shim K. CURE: An Efficient Clustering Algorithm of Large Databases. Proc. ACM SIGMOD Int'l Conf. Management of Data, ACM Press. New York, 1998: 73-84.
- [240] Shannon C E. A Mathematical Theory of Communication. Bell syst. Tech. J, XXVII-3, 1948. 379-423.



- [241] 苏新宇,杨建林,江念南,等. 数据仓库和数据挖掘. 北京:清华大学出版,2006.
- [242] 舒华英,齐佳音. 电信客户全生命周期管理. 北京:北京邮电大学出版社,2004.
- [243] Sun Ai Xin,Lim Ee Peng. Hierarchical Text Classification and Evaluation, in proceedings of 2001 IEEE International Conference on Data Mining, San Jose, California.
- [244] Syed Sibte Raza Abidi, Jason ong. A data Mining strategy for Inductive Data Clustering: A Synergy Between Self-Organizing Neural Networks and K-means Clustering Techniques. IEEE, 2000.
- [245] Zhang T, Ramakrishnan R, Livny M. BIRCH: An Efficient Data Clustering Method for Very large databases. In: Proc of the ACM SIGMOD Conference on Management of data, Montreal, Canada, June 1996.
- [246] 陶皖,李平,廖述梅. 当前基于本体的语义标注工具的分析. 安徽工程科技学院学报, 2005, 20(2).
- [247] Tan Ah-Hwee. Text Mining: The State of the Art and the Challenges. In Proceedings, PAKDD'99 workshop on Knowledge Discovery from Advanced Databases, Beijing, April 1999. 65-70.
- [248] 谭勇,荣秋生. 一个基于 K-means 的聚类算法的实现. 湖北民族学院学报, 2004, 22(01): 69-71.
- [249] Ted Pedersen, Rebecca. Bruce, Unsupervised Text Mining, Technical Report 97-CSE-9, Southern Methodist University, USA, 1997.
- [250] Tom Mitchell. Machine learning. McGraw Hill, 1996.
- [251] Zhang T Ramakrishnan R, Livny M. BIRCH: An Efficient Data Clustering Method for Very Large Databases. In Proc. of the ACM SIGMOD Conference on Management of data, Montreal, Canada, June 1996.
- [252] Grenander U. General Pattern Theory. Oxford University Press, 1993.
- [253] Anupam V Ureire, Kumar B. Automating Web Navigation with the WebVCR. In: roceedings of the 9th ACM-WWW International Conference. Amsterdam. 2000. US: ACM Press, 2000. 503-517.
- [254] Lin W, Alvarez S A, Ruiz C. Efficient Adaptive-support Association Rule Mining for Recommender System. Data Mining and Knowledge Discovery, 2002, 11(5): 83-105.
- [255] 王爱华,张铭,杨冬青,等. PCCS 部分聚类分类: 一种快速的 Web 文档聚类方法. 计算机研究与发展, 2001, 38(4).
- [256] 王芳. 基于数据挖掘的客户流失预测研究: [硕士学位论文]. 西南师范大学, 2003.
- [257] 王宏伟,詹荣开,贺汉根. 基于模糊聚类的改进模糊辨识方法. 电子学报, 2001, 29(4): 436-438.
- [258] 王守唐,高东杰. 基于 T-S 模糊模型的辨识算法. 控制与决策, 2001, 16(5): 630-636.
- [259] 王实,高文,李锦涛. Web 数据挖掘. 计算机科学, 2000, 27(4): 28-31.
- [260] 王实,高文,李锦涛,等. 路径聚类: 在 Web 站点中的知识发现. 计算机研究与发展, 2001, 38(4): 482-486.
- [261] 王实,高文. 数据挖掘中的聚类方法. 计算机科学, 2000, 27(4): 42-45.
- [262] 王维佳. 数量型数据关联规则挖掘及其在通信行业用户分析中的应用. 浙江统计, 2005(03): 28-30.
- [263] 王秀丽. 数据挖掘功能特性及其应用流程分析. 科技创业月刊, 2005(5): 151-152.
- [264] 王彦龙. 企业级数据仓库原理、设计与实践. 北京: 电子工业出版社, 2006.
- [265] 汪培庄,李洪兴. 模糊系统理论与模糊计算机. 北京: 科学出版社, 1996.
- [266] 王永庆. 人工智能原理与方法. 西安: 西安交通大学出版社, 1998.
- [267] 魏立梅,谢维信. 对手抑制式模糊 c 均值算法. 电子学报, 2000, 28(7): 63-66.
- [268] Wee W G. On Generalizations of Adaptive Algorithms and Application of the Fuzzy Sets Concept to Pattern Classification. Ph. D. thesis, Purdue Univ., Lafayette, Indiana, 1967.
- [269] Inmon W H. Building the Data Warehouse, 4ed. Wiley, 2005.
- [270] Inmon W H. 企业信息工厂. 北京: 电子工业出版社, 2004.
- [271] Willet P. Recent Trends in Hierarchical Document Clustering: A Critical Review, Information



Processing and Management, 1988, 24(5): 577-587.

- [272] 吴斌, 史忠植. 基于蚁群算法的 TSP 问题分段求解算法. 计算机学报, 2001, 24(12): 1328-1333.
- [273] 吴斌. 群体智能的研究及其在知识发现中的应用. [博士论文]. 中国科学院计算技术研究所, 2002.
- [274] Wu Bin, Shi Zhongzhi. A Clustering Algorithm Based On Swarm Intelligence, International Conferences on Info-tech & Info-net, Beijing, ICII'2001.
- [275] Xiangwen Guo, Weiyi Liu, Min Qian et al. Ontology-based information retrieval. Journal of Yunnan University. 2003, 25: 324-327.
- [276] Xiaogang Ruan. A Pattern Recognition Machine with Fuzzy Clustering Analysis. Proceedings of the 3rd World Congress on Intelligence Control and Automation. June 2000, Hefei. 2530-2534.
- [277] 肖菁, 商卫东. XML——新一代 Web 标记语言. 电脑与信息技术, 1999(3): 2-4.
- [278] Xie X L, Beni G. A Validity Measure for Fuzzy Clustering. IEEE Trans Patt. Anal Machine Intell, 1991, 13(8): 841-847.
- [279] 谢民主, 王加阳, 蒋外文. 数据仓库的多维数据模型的研究. 计算机工程与应用, 2004, 25.
- [280] Xie X, Zhang W, Yang Z. Adaptive Particle Swarm Optimization On Individual level, International Conference on Signal Processing (ICSP 2002), Beijing, China, 2002.
- [281] 刑东山, 沈钧毅. Web 使用挖掘的数据采集. 计算机工程, 2001, 28(1): 39-41.
- [282] 行小帅, 潘进, 焦李成. 基于免疫规划的 k-means 聚类算. 计算机学报, 2003, 26(5): 605-610.
- [283] 徐光宪, 刘建辉, 黄素芬. 电信行业中数据挖掘的应用研究. 现代管理科学, 2004(12): 8-9.
- [284] 徐贵红, 张健. 语义网的一阶逻辑推理技术支持. 软件学报, 2008, 19(12): 3091-3099.
- [285] 许海洋, 汪国安, 王万森. 模糊聚类分析在数据挖掘中的应用研究. 计算机工程与应用, 2005(17): 177-179.
- [286] 胥学跃. 电信营销管理. 北京: 北京邮电大学出版社, 2005.
- [287] 杨炳儒, 孙海洪. 基于双库协同机制的挖掘关联规则算法 Maradbem. 计算机研究与发展, 2002, 39(11): 1447-1455.
- [288] Yang H, Lee C. Automatic Category Generation for Text Documents by Self-Organizing Maps, Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks, 2000.
- [289] 杨家红, 肖松文. 产品生命周期评价系统研究. 计算机工程与科学, 2004(5): 66-69.
- [290] Yang Yiming, Jan O. Pederson. A Comparative Study on Feature Selection in Text Categorization. Proceedings of the 14th International Conference on Machine Learning, Nashville, TN, Morgan Kaufmann, 1997. 412-420.
- [291] 姚宏伟, 梅晓榕. 模糊聚类分析在模糊神经网络结构优化中的应用. 高技术通信, 2000(10): 64-66.
- [292] 叶进, 程泽凯, 林士敏. 基于贝叶斯网络的电信客户流失预测分析. 计算机工程与应用, 2005(14): 212-214.
- [293] 于剑, 程乾生. 关于 FCM 算法中的权重指数  $m$  的一点注记. 电子学报, 2003, 31(3): 478-480.
- [294] 于剑, 程乾生. 关于聚类有效性函数  $FP(u, c)$  的研究. 电子学报, 2001(7): 899-901.
- [295] 于宗民, 刘义宁, 祁国辉. 数据仓库项目管理实践. 北京: 人民邮电出版社, 2006.
- [296] 余一娇. 语义网和语义网格中的本体研究综述. Technical Report. 2004.
- [297] 俞士汶. 关于现代汉语词语的语法功能分类. <http://www.hne.com>.
- [298] 袁毓林. 语言的认知研究和计算分析. 北京: 北京大学出版社, 1998.
- [299] Zadeh L A. Fuzzy Sets. Inf Control, 1965, 8: 338-353.
- [300] 曾海颖. 客户关系管理中的数据挖掘. [硕士学位论文]. 南京航空航天大学, 2003.
- [301] 瞿裕忠, 胡伟, 郑东栋等. 关系数据库模式和本体间映射的研究综述. 计算机研究与发展, 2008, 45(2): 300-309.
- [302] 张娥, 冯秋红, 宣慧玉等. Web 使用模式研究中的数据挖掘. 计算机应用研究, 2001, 3: 80-83.



- [303] Zhang Tian, Ramakrishnan Raghu, Livny. Miron Birch: An efficient data clustering method for very large databases. In: Proceedings of the ACM SIGMOD Conference on Management of Data (SIGMOD 96), 1996. 103-114.
- [304] 张莉, 周伟达, 焦李成. 核聚类算法. 计算机学报, 2002, 25(6): 587-590.
- [305] 张海笑, 徐小明. 数据挖掘中分类方法的研究. 山西电子技术, 2005(2): 20-21.
- [306] 张磊, 杜小勇, 王珊. 移动通信客户预测流失分析. 计算机科学, 2003, 30(10).
- [307] 张维, 潘福铮. 一种基于遗传算法的模糊聚类. 湖北大学学报(自然科学版), 2002, 24(2): 101-104.
- [308] 张伟, 廖晓峰, 吴中福. 一种基于遗传算法的聚类新方法. 计算机科学, 2002, 29(6): 114-116.
- [309] 张卫丰, 徐宝文, 周晓宇等. Web 搜索引擎综述. 计算机科学, 2001, 28(9): 24-28.
- [310] 张文修, 梁怡. 遗传算法的数学基础. 西安: 西安交通大学出版社, 2000.
- [311] 张跃. 模糊数学方法及其应用. 北京: 煤炭工业出版社, 1992.
- [312] 张志顺, 胡勇刚, 赵宏伟等. 基于改进形式的遗传算法研究. 微电子学, 2002, 32(4): 273-275.
- [313] 张卫丰, 徐宝文, 周晓宇等. Web 搜索引擎综述. 计算机科学, 2001, 28(9): 24-28.
- [314] Zhang D D. Neural Networks System Design Methodology. Beijing: Tsinghua University Press, 1996.
- [315] 张纪会, 高齐圣, 徐心和. 自适应蚁群算法. 控制理论与应用, 2000, 17(1): 1-8.
- [316] 赵钊林. 应用数据挖掘技术研发通信业“离网预警”模型. 福建工程学院学报, 2005, 3(10): 301-303.
- [317] 赵丹群. 数据挖掘: 原理、方法及其应用. 现代图书情报技术, 2000(6): 41-44.
- [318] 赵志荣, 徐恩元. 论网络信息资源. 情报杂志, 2001(8): 28-30.
- [319] Zheng Yan, Huang Ronghuai, Zhan Xiaosu, Zhang Yan. A Clustering Algorithm for Customer Behavior Analysis. The 6th International Conference on Computer-Aided Industrial Design and Conceptual Design (CAID&CD'2005), 1791-1794.
- [320] Zheng Yan, Cheng Xiaochun, Huang Ronghuai et al. A Comparative Study on Text Mining Methods. The 2nd International Conference on Advanced Data Mining and Applications, August 14-16 2006, Xi'An, China. 644-65.
- [321] 郑志军, 林霞光, 郑守淇. 一种基于神经网络的数据挖掘方法. 西安建筑科技大学学报, 2004, 32(01): 28-30.
- [322] 郑之开, 张广凡, 邵惠鹤. 数据采掘与知识发现: 回顾和展望. 信息与控制, 1999, 28(5): 357-365.
- [323] 钟晓, 马少平, 张钺等. 数据挖掘综述. 模式识别与人工智能, 2001, 14(1): 48-53.
- [324] 周强. 基于语料库和面向统计学的自然语言处理技术介绍. 计算机科学, 1995, 22(4): 36-40.
- [325] 陈莉, 焦李成. Interne/Web 数据挖掘研究现状及最新进展. 西安电子科技大学学报(自然科学版), 2001, 28(1): 114-118.